

USP

Campus de São Carlos

*APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS PARA
PREVISÃO DE PROPRIEDADES DOS SOLOS TROPICAIS*

SANDRA FABIANA RODGHER

ORIENTADOR: PROF. DR. GLAUCO TULIO PESSA FABBRI

UNIVERSIDADE DE SÃO PAULO



ESCOLA DE ENGENHARIA DE SÃO CARLOS

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE TRANSPORTES - STT

Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO


Data de entrada no Serviço: 02./08/02

Ass.: 

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
PREVISÃO DE PROPRIEDADES DOS SOLOS TROPICAIS

SANDRA FABIANA RODGHER

DEDALUS - Acervo - EESC



31100037067

Tese apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Engenharia Civil - Transportes.


Orientador: Prof. Dr. Glauco Tulio Pessa Fabbri

São Carlos

2002



Class. TESE - EESC
Cutt. 4887
Tombo T0178/02
Sysno 1264199



Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca - EESC/USP

R691a Rodgher, Sandra Fabiana
Aplicação de redes neurais artificiais para
previsão de propriedades dos solos tropicais / Sandra
Fabiana Rodgher. -- São Carlos, 2002.

Tese (Doutorado) -- Escola de Engenharia de São
Carlos-Universidade de São Paulo, 2002.
Área : Transportes.
Orientador: Prof. Dr. Glauco Tulio Pessa Fabbri.

1. Previsão de propriedades dos solos tropicais.
2. Redes neurais artificiais. 3. Classificação de
solos. I. Título.

FOLHA DE JULGAMENTO


Candidata: Engenheira **SANDRA FABIANA RODGHER**

Tese defendida e julgada em 27-05-2002 perante a Comissão Julgadora:



Prof. Doutor **GLAUCO TÚLIO PESSA FABBRI (Orientador)**
(Escola de Engenharia de São Carlos/USP)

APROVADO



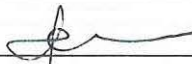
Prof. Associado **JOSÉ LEOMAR FERNANDES JUNIOR**
(Escola de Engenharia de São Carlos/USP)

APROVADA




Prof. Associado **ALEXANDRE BENETTI PARREIRA**
(Escola de Engenharia de São Carlos/USP)

APROVADO



Profª. Doutora **SANDRA ODA**
(Universidade Estadual de Maringá/UEM)

APROVADO

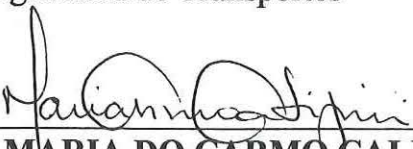


Profª. Associada **LIÉDI LEGI BARANI BERNUCCI**
(Escola Politécnica/USP)

Aprovada



Prof. Doutor **EDSON MARTINS DE AGUIAR**
Coordenador do Programa de Pós-Graduação em
Engenharia de Transportes



Profª. Assoc. **MARIA DO CARMO CALIJURI**
Presidente da Comissão de Pós-Graduação da EESC

DEDICATÓRIA

À minha família,
meus pais Osmar e Geny,
minhas irmãs Solange e Suzelei e meu cunhado Marcus,
pelo carinho, estímulo e,
sem os quais este trabalho não seria possível;

Ao meu esposo Marcelo, pela sua paciência e compreensão;

À minha querida filha, Marcela Fabiana, minha vida.

AGRADECIMENTOS

A Deus, que sempre me guiou em minhas conquistas;

Ao meu orientador, Prof. Dr. Glauco Tulio Pessa Fabbri, cuja orientação, compreensão, paciência, presteza e clareza foram imprescindíveis para conclusão deste trabalho;

Ao Prof. Dr. André C. Ponce de Leon Ferreira de Camargo por ter-me ensinado os primeiros conceitos da técnica de Redes Neurais Artificiais (RNAs);

A todos os professores do Departamento de Transportes, pelos ensinamentos transmitidos;

Aos funcionários do Departamento de Transportes e em especial: Heloísa, Lílian, Magali, Bete, Vicente e Carlos;

Aos técnicos do Laboratório de Estradas do STT, à Jisela e ao Delfos pelos auxílios na coleta das amostras;

Aos amigos do Departamento de Transportes e em especial: Sandra Margarido, Cristina, Simonne, Suelly, Sandra Oda, Benedito Coutinho e Pastor.

Ao CNPq pela concessão da bolsa de estudo;

Enfim, agradeço a todos aqueles que, embora não tenham sido mencionados por nome, de uma forma ou de outra, contribuíram para a realização deste trabalho.

SUMÁRIO

LISTA DE FIGURAS.....	x
LISTA DE TABELAS.....	xvi
LISTA DE SÍMBOLOS.....	xvii
LISTA DE ABREVIATURAS E SIGLAS.....	xix
RESUMO.....	xxii
<i>ABSTRACT</i>	xxiv
CAPÍTULO 1: CONSIDERAÇÕES INICIAIS.....	1
1.1. INTRODUÇÃO.....	1
1.2. ESTRUTURA DO TRABALHO.....	6
CAPÍTULO 2: REDES NEURAIS ARTIFICIAIS.....	8
2.1. HISTÓRICO.....	8
2.2. NEURÔNIO BIOLÓGICO.....	10
2.3. REDES NEURAIS ARTIFICIAIS (RNAs).....	12
2.4. O MODELO COMPUTACIONAL DO NEURÔNIO.....	15
2.5. FUNÇÕES DE ATIVAÇÃO.....	17
2.6. ARQUITETURA E TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS.....	18
2.7. TIPOS DE APRENDIZAGEM.....	19
2.8. TIPOS DE REDES NEURAIS ARTIFICIAIS.....	20
2.8.1. <i>PERCEPTRON</i>	21
2.8.2. MODELO ADALINE.....	22
2.8.3. <i>PERCEPTRON MULTI-LAYER (MLP)</i>	22
2.8.4. REDES FUNÇÕES BASE RADIAIS (<i>RADIAL BASIS FUNCTIONS</i>).....	25

2.8.5. REDES DE KOHONEN.....	26
2.8.6. REDE DE HOPFIELD.....	28
CAPÍTULO 3: APLICAÇÕES DE REDES NEURAIAS ARTIFICIAIS	
NA ENGENHARIA CIVIL.....	28
3.1. INTRODUÇÃO.....	28
3.1.1. CLASSIFICAÇÃO E PREVISÃO DO COMPORTAMENTO DE MATERIAIS DE CONSTRUÇÃO.....	28
3.1.2. CONSTRUÇÃO E MANUTENÇÃO DE PAVIMENTOS.....	32
3.1.3. PLANEJAMENTO DOS TRANSPORTES.....	38
3.1.4. GEOTECNIA.....	41
3.1.5. HIDRÁULICA E SANEAMENTO.....	42
CAPÍTULO 4: CLASSIFICAÇÕES GEOTÉCNICAS DE SOLOS.....	44
4.1. A CLASSIFICAÇÃO HRB.....	44
4.2. CLASSIFICAÇÃO MCT PARA SOLOS TROPICAIS.....	47
4.2.1. INTRODUÇÃO.....	47
4.2.2 A CLASSIFICAÇÃO MCT.....	48
4.2.3 COMPACTAÇÃO MINI-PROCTOR.....	51
4.3. A UTILIZAÇÃO DO ENSAIO DE ADSORÇÃO DE AZUL DE METILENO PELO MÉTODO DA MANCHA NA CARACTERIZAÇÃO DE SOLOS.....	52
4.3.1. ESTUDOS REALIZADOS NO BRASIL.....	55
4.4. A UTILIZAÇÃO DAS CORES NA CLASSIFICAÇÃO DE SOLOS.....	60
4.4.1 A ORIGEM DA COR DO SOLO.....	61
4.4.2 SISTEMA DE COR DE <i>MUNSELL</i>	62
4.4.3. ESCALA <i>MUNSELL</i> DE CORES PARA SOLOS.....	63
CAPÍTULO 5: MATERIAIS E MÉTODOS.....	68
5.1. COLETA DOS MATERIAIS.....	68
5.2. MÉTODOS DE ENSAIOS.....	71
5.2.1. MASSA ESPECÍFICA DOS SÓLIDOS.....	71

5.2.2. GRANULOMETRIA POR SEDIMENTAÇÃO.....	71
5.2.3. LIMITE DE LIQUIDEZ.....	71
5.2.4. LIMITE DE PLASTICIDADE.....	71
5.2.5. MINI-CBR, EXPANSÃO E CONTRAÇÃO.....	71
5.2.6. MINI-MCV E PERDA DE MASSA POR IMERSÃO.....	72
5.2.7. ADSORÇÃO DE AZUL DE METILENO PELO MÉTODO DA MANCHA.....	72
5.2.7.1. APARELHAGEM E MATERIAIS.....	73
5.2.7.2. EXECUÇÃO DO ENSAIO.....	73
5.2.8. IDENTIFICAÇÃO VISUAL DAS CORES.....	74
5.3. REDES NEURAIS ARTIFICIAIS IMPLEMENTADAS.....	74
5.4. SIMULADOR <i>EASYN</i> 7.5.....	77
CAPÍTULO 6: APRESENTAÇÃO E ANÁLISE DOS RESULTADOS.....	79
6.1. INTRODUÇÃO.....	79
6.2. RESULTADOS DAS CLASSIFICAÇÕES GEOTECNICAS (MCT E HRB) PELA ADSORÇÃO DE AZUL DE METILENO E PELAS CORES (<i>MUNSELL SOIL COLOR CHARTS</i>).....	80
6.2.1. DISTRIBUIÇÃO DAS AMOSTRAS SEGUNDO A CLASSE MCT E A CLASSE PEDOLÓGICA.....	80
6.2.2. CLASSIFICAÇÕES HRB <i>VERSUS</i> MCT.....	82
6.2.3. CLASSIFICAÇÃO DOS SOLOS POR ADSORÇÃO DE AZUL DE METILENO <i>VERSUS</i> MCT.....	84
6.2.4. CLASSIFICAÇÃO DOS SOLOS POR CORES.....	85
6.3. PROPRIEDADES GEOTÉCNICAS DE INTERESSE.....	87
6.3.1. MASSA ESPECÍFICA DOS SÓLIDOS.....	87
6.3.2. GRANULOMETRIA.....	88
6.3.3. LIMITE DE LIQUIDEZ E LIMITE DE PLASTICIDADE.....	88
6.3.4. MINI-CBR, EXPANSÃO E CONTRAÇÃO.....	88
6.3.4.1. UMIDADE ÓTIMA.....	89
6.3.4.2. MASSA ESPECÍFICA SECA MÁXIMA.....	90

6.3.4.3. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA.....	92
6.3.4.4. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA.....	93
6.3.4.5. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA.....	95
6.3.4.6. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA.....	96
6.4. COMPARAÇÃO ENTRE A PREVISÃO DE PROPRIEDADES DOS SOLOS DA CLASSIFICAÇÃO MCT E OS RESULTADOS OBTIDOS EM LABORATÓRIOS.....	98
6.5. RELAÇÃO DAS PROPRIEDADES GEOTECNICAS COM O VALOR DE AZUL (VA).....	99
6.5.1. UMIDADE ÓTIMA <i>VERSUS</i> VALOR DE AZUL.....	100
6.5.2. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA <i>VERSUS</i> VALOR DE AZUL.....	101
6.6. VARIAÇÕES DOS VALORES DAS PROPRIEDADES EM FUNÇÃO DA ENERGIA DE COMPACTAÇÃO.....	103
6.6.1. UMIDADE ÓTIMA NA ENERGIA NORMAL <i>VERSUS</i> UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	103
6.6.2. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA NORMAL <i>VERSUS</i> MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA INTERMEDIÁRIA.....	104
6.6.3. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL <i>VERSUS</i> MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	105
6.6.4. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL <i>VERSUS</i> MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	106
6.6.5. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL <i>VERSUS</i> EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	107

6.6.6. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL <i>VERSUS</i> CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	108
6.7. REDES NEURAIAS ARTIFICIAIS E REGRESSÕES MÚLTIPLAS PARA PREVISÃO DE PROPRIEDADES DOS SOLOS.....	108
6.7.1. UMIDADE ÓTIMA.....	110
6.7.1.1. UMIDADE ÓTIMA NA ENERGIA NORMAL.....	110
6.7.1.2. UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	112
6.7.1.3. COMENTÁRIOS.....	115
6.7.2. MASSA ESPECÍFICA SECA MÁXIMA.....	116
6.7.2.1. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA NORMAL.....	116
6.7.2.2. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA INTERMEDIÁRIA.....	119
6.7.2.3. COMENTÁRIOS.....	122
6.7.3. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA.....	123
6.7.3.1. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL.....	123
6.7.3.2. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	126
6.7.3.3. COMENTÁRIOS.....	128
6.7.4. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA.....	129
6.7.4.1. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL.....	129
6.7.4.2. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	131
6.7.4.3. COMENTÁRIOS.....	135
6.7.5. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA.....	136
6.7.5.1. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL.....	136

6.7.5.2. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	138
6.7.5.3. COMENTÁRIOS.....	140
6.7.6. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA.....	141
6.7.6.1. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL.....	141
6.7.6.2. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA.....	144
6.7.6.3. COMENTÁRIOS.....	146
CAPÍTULO 7: CONSIDERAÇÕES FINAIS E CONCLUSÕES.....	147
7.1. INTRODUÇÃO.....	147
7.2. RELAÇÕES ENTRE AS PROPRIEDADES TECNOLÓGICAS DOS SOLOS ESTUDADOS E O VALOR DE AZUL.....	147
7.3. RELAÇÕES ENTRE AS PROPRIEDADES TECNOLÓGICAS DOS SOLOS ESTUDADOS.....	148
7.4. REDES NEURAIIS ARTIFICIAIS (RNAs).....	149
7.5. RNAs <i>VERSUS</i> REGRESSÕES MÚLTIPLAS.....	151
REFERÊNCIAS BIBLIOGRÁFICAS.....	153
ANEXO A: LOCALIZAÇÃO DAS AMOSTRAS, CLASSE PEDOLÓGICA, CLASSIFICAÇÃO MCT E MASSA ESPECÍFICA DOS SÓLIDOS.....	164
ANEXO B: CLASSIFICAÇÃO DE SOLOS HRB (HIGHWAY RESEARCH BOARD).....	171
ANEXO C: VALOR DE AZUL (VA), COEFICIENTE DE ATIVIDADE (CA) E GRAUS DE ATIVIDADE.....	175

ANEXO D: CLASSIFICAÇÃO DE SOLOS POR CORES <i>(MUNSELL SOIL COLOR CHARTS, 1975)</i>	180
ANEXO E: CLASSIFICAÇÃO MCT E GRANULOMETRIA	184
ANEXO F: ENSAIOS DE LIMITE DE LIQUIDEZ E DE PLASTICIDADE	191
ANEXO G: RESUMO DAS PROPRIEDADES DOS SOLOS NA UMIDADE ÓTIMA PARA A ENERGIA NORMAL E DOS RESULTADOS DOS ENSAIOS DE MINI-CBR, EXPANSÃO E CONTRAÇÃO NA ENERGIA NORMAL	195
ANEXO H: RESUMO DAS PROPRIEDADES DOS SOLOS NA UMIDADE ÓTIMA PARA A ENERGIA INTERMEDIÁRIA E DOS RESULTADOS DOS ENSAIOS DE MINI-CBR, EXPANSÃO E CONTRAÇÃO NA ENERGIA INTERMEDIÁRIA	224
ANEXO I: VERIFICAÇÃO DA CONCORDÂNCIA ENTRE RESULTADOS PREVISTOS PELA CLASSIFICAÇÃO MCT E OBTIDOS EM LABORATÓRIO	253
ANEXO J: REGRESSÕES LINEARES SIMPLES	258
ANEXO L: REDES NEURAS ARTIFICIAIS	265
ANEXO M: REGRESSÕES MÚLTIPLAS	278

LISTA DE FIGURAS

Figura 2.1 - Representação esquemática de um neurônio biológico.....	11
Figura 2.2 - Modelo não-linear de um neurônio, segundo HAYKIN (1994).....	16
Figura 2.3 - Funções de ativação linear e <i>threshold</i> ou limiar.....	18
Figura 2.4 - Funções de ativação <i>piecewise</i> linear e sigmóide logística.....	18
Figura 2.5 - Topologia de um <i>Perceptron</i> simples com uma única saída.....	21
Figura 2.6 – Rede <i>Perceptron MultiLayer</i> (MLP), treinadas com o algoritmo <i>backpropagation</i>	23
Figura 4.1 - Ábaco da classificação MCT (NOGAMI <i>et al.</i> , 1993).....	49
Figura 4.2 - Variação da adsorção de azul de metileno em função da composição das argilas, segundo LAUTRIN (1987).....	55
Figura 4.3 - Ábaco para caracterização do grau de atividade da fração argila dos solos, segundo FABBRI (1994).....	60
Figura 4.4 - Triângulo de cores de acordo com o sistema <i>Munsell</i> de cores (PEDROSA, 1982).....	63
Figura 4.5 – Ilustração da contribuição das cores vermelha e amarela na formação do matiz. (PRADO, 1993).....	65
Figura 4.6 - Distribuição do matiz, valor e croma do sistema <i>Munsell</i> (<i>Ku School of Architecture</i> , 2000).....	66
Figura 5.1 - Mapa do município de São Carlos (SP), mostrando a localização dos pontos de coletas das amostras de solos estudadas.....	70
Figura 5.2 - Tela de entrada do aplicativo <i>EASYNN 7.5</i>	77
Figura 6.1 - Localização das amostras no ábaco da Classificação MCT, codificadas pela classe pedológica.....	81

Figura 6.2 – Localização dos solos estudados no ábaco proposta por FABBRI (1994), codificados segundo a classe MCT.....	84
Figura 6.3 – Valores das umidades ótimas na energia normal para os solos estudados, codificados segundo a classe MCT.....	89
Figura 6.4 – Valores das umidades ótimas na energia intermediária para os solos estudados, codificados segundo a classe MCT.....	90
Figura 6.5 – Valores das massas específicas secas máximas na energia normal para os solos estudados, codificados segundo a classe MCT.....	91
Figura 6.6 – Valores das massas específicas secas máximas na energia intermediária para os solos estudados, codificados segundo a classe MCT.....	91
Figura 6.7 – Valores do Mini-CBR na umidade de moldagem obtido na umidade ótima para os solos estudados na energia normal, codificados segundo a classe MCT.....	92
Figura 6.8 – Valores do Mini-CBR na umidade de moldagem obtido na umidade ótima para os solos estudados na energia intermediária, codificados segundo a classe MCT.....	93
Figura 6.9 – Valores do Mini-CBR após 24 h de imersão obtido na umidade ótima para os solos estudados na energia normal, codificados segundo a classe MCT.....	94
Figura 6.10 – Valores do Mini-CBR após 24 h de imersão obtido na umidade ótima para os solos estudados na energia intermediária, codificados segundo a classe MCT.....	94
Figura 6.11 – Valores da expansão obtida na umidade ótima para os solos estudados na energia normal, codificados segundo a classe MCT.....	95
Figura 6.12 – Valores da expansão obtida na umidade ótima para os solos estudados na energia intermediária, codificados segundo a classe MCT.....	96

Figura 6.13 – Valores da contração obtida na umidade ótima para os solos estudados na energia normal, codificados segundo a classe MCT.....	97
Figura 6.14 – Valores da contração obtida na umidade ótima para os solos estudados na energia intermediária, codificados segundo a classe MCT.....	97
Figura 6.15 – Relação entre a umidade ótima na energia normal e o valor de azul.	100
Figura 6.16 – Relação entre a umidade ótima na energia intermediária e o valor de azul.....	101
Figura 6.17 – Relação entre a contração obtida na umidade ótima na energia normal e o valor de azul.....	102
Figura 6.18 – Relação entre a contração obtida na umidade ótima na energia intermediária e o valor de azul.....	102
Figura 6.19 – Umidade ótima na energia normal <i>versus</i> umidade ótima na energia intermediária.....	103
Figura 6.20 – Massa específica seca máxima na energia normal <i>versus</i> massa específica seca máxima na energia intermediária.....	104
Figura 6.21 – Mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal <i>versus</i> mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária....	105
Figura 6.22 – Mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal e o mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária.....	106
Figura 6.23 – Relação entre as expansões obtidas nas umidades ótimas nas energias normal e intermediária.....	107
Figura 6.24 – Relação entre as contrações obtidas nas umidades ótimas nas energias normal e intermediária.....	108
Figura 6.25 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ e $EMR_{\text{mín}}$, para a previsão da umidade ótima na energia normal.....	111
Figura 6.26 – Valores reais das umidades ótimas na energia normal (ensaios) <i>versus</i> os previstos pela RNA.....	111

Figura 6.27 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da umidade ótima na energia intermediária.....	113
Figura 6.28 – A arquitetura da RNA que apresentou EMR_{min} para a previsão da umidade ótima na energia intermediária.....	113
Figura 6.29 – Valores reais das umidades ótimas na energia intermediária (ensaios) <i>versus</i> os previstos pela RNA, para os casos de $R^2_{\text{máx}}$ e de EMR_{min}	114
Figura 6.30 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da massa específica seca máxima na energia normal.....	117
Figura 6.31 – A arquitetura da RNA que apresentou EMR_{min} para a previsão da massa específica seca máxima na energia normal.....	117
Figura 6.32 – Valores reais das massas específicas secas máximas na energia normal (ensaios) <i>versus</i> os previstos pela RNA, para os casos de $R^2_{\text{máx}}$ e de EMR_{min}	118
Figura 6.33 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da massa específica seca máxima na energia intermediária.....	120
Figura 6.34 – A arquitetura da RNA que apresentou EMR_{min} para a previsão da massa específica seca máxima na energia intermediária.....	120
Figura 6.35 – Valores reais das massas específicas secas máximas na energia intermediária (ensaios) <i>versus</i> os previstos pela RNA, para os casos de $R^2_{\text{máx}}$ e de EMR_{min}	121
Figura 6.36 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão de mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal.....	124
Figura 6.37 – A arquitetura da RNA que apresentou EMR_{min} para a previsão do mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal.....	124

Figura 6.38 – Valores reais dos mini-CBRs na umidade de moldagem obtidos na umidade ótima na energia normal (ensaios) <i>versus</i> os previstos pela RNA, para os casos de $R^2_{máx}$ e de $EMR_{mín}$	125
Figura 6.39 – A arquitetura da RNA que apresentou $R^2_{máx}$ e $EMR_{mín}$ para a previsão do mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária.....	127
Figura 6.40 – Valores reais dos mini-CBRs na umidade de moldagem obtidos na umidade ótima na energia intermediária (ensaios) <i>versus</i> os previstos pela RNA.....	128
Figura 6.41 – A arquitetura da RNA que apresentou $R^2_{máx}$ e $EMR_{mín}$ para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal.....	130
Figura 6.42 – Valores reais dos mini-CBRs após 24 h de imersão obtidos na umidade ótima na energia normal (ensaios) <i>versus</i> os previstos pela RNA.....	131
Figura 6.43 – A arquitetura da RNA que apresentou $R^2_{máx}$ para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária.....	132
Figura 6.44 – A arquitetura da RNA que apresentou $EMR_{mín}$ para a previsão de mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária.....	133
Figura 6.45 – Valores reais dos Mini-CBRs após 24 h de imersão obtidos na umidade ótima na energia intermediária (ensaios) <i>versus</i> os previstos pela RNA, para os casos de $R^2_{máx}$ e de $EMR_{mín}$	134
Figura 6.46 – A arquitetura da RNA que apresentou $R^2_{máx}$ para a previsão da expansão obtida na umidade ótima na energia normal.....	136
Figura 6.47 – Valores reais das expansões obtidos na umidade ótima na energia normal (ensaios) <i>versus</i> os previstos pela RNA.....	137

Figura 6.48 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da expansão obtida na umidade ótima na energia intermediária.....	139
Figura 6.49 – Valores reais das expansões obtidos na umidade ótima na energia intermediária (ensaios) <i>versus</i> os previstos pela RNA.....	139
Figura 6.50 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da contração obtida na umidade ótima na energia normal.....	141
Figura 6.51 – A arquitetura da RNA que apresentou $EMR_{\text{mín}}$ para a previsão da contração obtida na umidade ótima na energia normal.....	142
Figura 6.52 – Valores reais das contrações obtidos na umidade ótima na energia normal (ensaios) <i>versus</i> os previstos pela RNA, para os casos de $R^2_{\text{máx}}$ e de $EMR_{\text{mín}}$	143
Figura 6.53 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ e $EMR_{\text{mín}}$ para a previsão da contração obtida na umidade ótima na energia intermediária.....	144
Figura 6.54 – Valores reais das contrações obtidos na umidade ótima na energia intermediária (ensaios) <i>versus</i> os previstos pela RNA.....	145

LISTA DE TABELAS

Tabela 4.1 - Classificação de solos da HRB, adaptada de ASTM (1990).....	46
Tabela 4.2 - Valores das propriedades dos solos de cada classe MCT (NOGAMI <i>et al.</i> , 1993).....	50
Tabela 4.3 - Composições das frações argila utilizadas por LAUTRIN (1987).....	54
Tabela 5.1 - Áreas de ocorrência de cada classe pedológica no município de São Carlos (SP).....	69
Tabela 5.2 - Número de amostras coletadas em função das áreas de ocorrência de cada classe pedológica no município de São Carlos (SP).....	69
Tabela 5.3 - Divisão dos conjuntos de treinamento, teste e validação em função de cada classe pedológica.....	76
Tabela 6.1 – Distribuição das amostras segundo as classes pedológica e MCT.....	82
Tabela 6.2 – Resultados da classificação HRB codificados segundo a classe MCT, para os solos de comportamento laterítico e não laterítico.....	83
Tabela 6.3 - Classificação por cores (<i>Munsell Soil Color Charts</i> , 1975) Segundo o número de amostras por classe pedológica.....	86
Tabela 6.4 – Variação dos valores da massa específica dos sólidos das amostras estudadas.....	88
Tabela 6.5 – Amostras que apresentam discordância em duas ou três propriedades em relação aos valores previstos pela Classificação MCT.....	99

LISTA DE SÍMBOLOS

REDES NEURAIS ARTIFICIAIS

- Neurônio Artificial

θ	Limiar (<i>threshold</i>) do neurônio
n	Número de entradas do neurônio
u_k	Somatório
w_i	Peso correspondente a cada entrada x_i

- Função de Ativação

$\phi(t+1)$	Função de ativação
a_k	Estado de ativação no instante t
t	Representa o instante da transformação do estado de ativação
y_k	Saida produzida

- Aprendizado

Δw_{ij}	Variação do peso sináptico
η	Taxa de aprendizado
α	Momentum
y_i	Saida do neurônio i
x_j	Entrada do neurônio j
e_k	Erro
d_k	Saida desejada

y_k	Saída calculada
w_{ij}	Peso da conexão
a_i	Constantes, com $a_2 > 0$
x_i	Entrada do neurônio i
y_j	Saída do neurônio i

▪ Classificação de Solos

c^3	Coefficiente que traduz a argilosidade do solo
d^4	Coefficiente angular da parte mais inclinada do ramo seco da curva de compactação correspondente a 12 golpes
e^5	Coefficiente que expressa o caráter laterítico do solo
P_f	Porcentagem em peso que o solo contém da fração cujo grau de atividade se quer avaliar
P_i	Perda de peso característica do solo
Va e Vb	Valor de azul
w	Teor de umidade do solo ensaiado

▪ Métodos

EMR	erro médio relativo
EMR_{\min}	erro médio relativo mínimo
P_{200}	Porcentagem do solo que passa na #0,074 mm
P_{Real}	Valor real da propriedade do solo (ensaios laboratoriais)
P_{RNA}	Valor previsto da propriedade pela RNA
R^2	Coefficiente de determinação
R^2_{\max}	Coefficiente de determinação máximo

LISTA DE ABREVIATURAS E SIGLAS

AASHO	<i>American Association of State Highway Officials</i>
AASHTO	<i>American Association of State Highway and Transportation Officials</i>
ADALINE	<i>Adaptive Linear Element</i>
ANN	<i>Artificial Neural Network</i>
AQ	Areia Quartzosa Profunda
ART	Redes Baseadas na Teoria da Ressonância Adaptativa
CA	Coefficiente de atividade
CBR	<i>Califórnia Bearing Ratio</i>
C _i	Contração obtida na umidade ótima na energia normal
C _n	Contração obtida na umidade ótima na energia normal
CTC	Capacidade de Troca Catiônica
DER	Departamento de Estradas de Rodagem
DNER	Departamento Nacional de Estradas de Rodagem
E _i	Expansão obtida na umidade ótima na energia intermediária
E _n	Expansão obtida na umidade ótima na energia normal
ETE	Estação de Tratamento de Esgotos
FWD	<i>Falling Weight deflectometer</i>
HRB	<i>Highway Research Board</i>
IA	Inteligência Artificial
IAC	Instituto Agrônomo de Campinas
IG	Índice de Grupo
IP	Índice de Plasticidade
L	Laterítico
LA	Areias lateríticas

LA'	Solos arenosos lateríticos
LE	atossolo Vermelho-Escuro
LG'	Solos argilosos lateríticos
Li	Litólico
LL	Limite de Liquidez
LP	Limite de Plasticidade
LR	Latossolo Roxo
LV	Latossolo Vermelho-Amarelo
MCT	Miniatura, Tropical, Compactado
MCV	<i>Moisture Condition Value</i>
ME	Método de Ensaio
mini-CBR(24hi)	Mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária
mini-CBR(24hn)	Mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal
mini-CBR(Hmi)	Mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária
mini-CBR(Hmn)	Mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal
MLP	<i>Multilayer Perceptron</i>
N	Não laterítico
NA	Areias não lateríticas
NA'	Solos arenosos não lateríticos
NG'	Solos argilosos não lateríticos
NS'	Solos siltosos não lateríticos
PV	Podzólico Vermelho-Amarelo
RBF	Redes de Funções de Base Radial
RNA	Rede Neural Artificial
RTR	<i>Recommandation pour Terrassements Routiers</i>
SE	Superfície Específica
TE	Terra Roxa Estruturada
USCS	<i>Unified Soil Classification System</i>

VT	volume total de azul de metileno consumido por 1 g de amostra de solo integral (ml)
Woi	Umidade ótima na energia intermediária
Won	Umidade ótima na energia normal
ρ_i	Massa específica seca máxima na energia intermediária
ρ_n	Massa específica seca máxima na energia normal
(#0,42), (#0,074), (#0,005)	Frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm

RESUMO

RODGHER, SANDRA FABIANA. Aplicação de Redes Neurais Artificiais para Previsão de Propriedades dos Solos Tropicais. São Carlos, 2002. Tese – Escola de Engenharia de São Carlos, Universidade de São Paulo.

Este trabalho propõe 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. Esse método tem a finalidade de simplificar o processo de obtenção das propriedades dos solos, eliminando a lentidão dos procedimentos de ensaios e os cálculos a serem realizados, além de reduzir a dificuldade de ter que fazê-los utilizando os métodos tradicionais.

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 24 h 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 (V_a), coeficiente de atividade (CA), análise granulométrica por sedimentação (peneiras #0,42, #0,074 e #0,005), parâmetros da classificação MCT (c' , P_i , d' e e') e classificação por cores (croma, valor e matiz). O aplicativo utilizado para treinar as RNAs foi o *EASYN* 7.5, que se baseia em redes *Multilayer Perceptron* e no algoritmo de treinamento *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, os desempenhos das RNAs para mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão e expansão obtidas na umidade ótima das energias normal e intermediária foram menos satisfatórios.

De maneira geral, os resultados obtidos nesse estudo sugerem que modelos que fazem uso de Redes Neurais Artificiais para previsão de propriedades geotécnicas de solos para pavimentação apresentam-se como promissores e podem, no futuro, contribuir para a melhoria e redução de custos da fase de estudo geotécnico para implantação de vias em municípios de pequeno e médio portes.

Palavras chave: Previsão de Propriedades dos Solos Tropicais

Redes Neurais Artificiais

Classificação de solos

ABSTRACT

RODGER, SANDRA FABIANA. Application of Artificial Neural Networks for Forecast the Properties of Tropical Soils. São Carlos, 2002. 306p. Thesis (Doctorate) - São Carlos Engineering School, University of São Paulo.

The application of the technique of Artificial Neural Networks (ANNs) for the forecast of geotechnical properties of the soils in São Carlos, a municipal district in the of São Paulo State, based on other properties determined preliminary is the purpose of this work. This method has the goal of simplifying the process of obtaining the properties of the soils, eliminating the slowness of the tests procedures and the calculations to be accomplished, besides reducing the difficulty of having to do them using the traditional methods.

One hundred and ninety seven ANNs were simulated for the forecast of the following properties: optimum moisture content, dry density, mini-CBR in the molding humidity obtained in the optimum moisture content, mini-CBR obtained after 24 h of soaking in the optimum moisture content, expansion and contraction obtained in the optimum moisture content for the normal and intermediate energies. In the training of ANNs a base of data was used with a total of one hundred and one samples that, besides containing the values of the properties "objective" for forecast, it also contains: methylene blue value (Va), activity coefficient (CA), granulometric analysis for sedimentation (sieves #0,42, #0,074 and #0,005), parameters of the MCT classification (c' , P_i , d' and e') and classification by colors (chroma, value and hue). The application used to train ANNs was EasyNN 7.5, that bases on nets Multilayer Perceptron and in the training algorithm Backpropagation.

For the forecast of geotechnical properties of the soils, the performance of the nets were very good for optimum moisture content, dry density and contraction in the normal and intermediate energies. However, the performance of ANNs for mini-CBR in the molding humidity, mini-CBR after 24 h of immersion and expansion obtained in the optimum moisture content of the normal and intermediate energies were less satisfactory.

In a general way, the results obtained in this study suggest that the models that use Artificial Neural Networks for forecast of geotechnical properties of soils come as promising and can, in the future, contribute for the improvement and costs reduction during the period of geotechnical study in the implantation of roads in small and medium sized municipal districts.

Keywords: Forecast of Properties of the Tropical Soils

Artificial Neural Networks

Classification of soils

CAPÍTULO 1: CONSIDERAÇÕES INICIAIS

1.1 INTRODUÇÃO

O conhecimento das propriedades dos materiais geotécnicos (solos) envolvidos na implantação de uma via urbana ou interurbana é de extrema importância, tanto no que diz respeito ao subsolo de fundação, quanto aos materiais de empréstimo utilizados na construção de aterros e do pavimento. As características, peculiares de cada solo, são determinantes na resposta que a via apresentará frente à solicitação do tráfego e à ação dos agentes climáticos.

A falta de recursos, comum a quase todos os setores da administração pública municipal, também influi negativamente sobre as atividades de pavimentação nas cidades brasileiras. Normalmente, os municípios não apresentam tradição de planejar as intervenções nos pavimentos e de controlar a qualidade das obras executadas. Essa escassez de recursos disponíveis para investimento em projetos de pavimentos, a utilização de procedimentos ultrapassados e inadequados de manutenção, a falta de controle de qualidade e o custo da geotecnia são fatores que agravam os problemas dos organismos viários municipais, principalmente nas cidades de pequeno e médio porte.

Os municípios buscam alternativas baratas para a pavimentação das ruas e vicinais. Assim, procurando-se estimar corretamente as propriedades dos materiais (solos), pode-se adequar melhor o orçamento e gastos do município, evitando desta forma a geração de altos custos para a manutenção e conservação dos pavimentos.

No Brasil, grande parte do território nacional é recoberta por solos lateríticos ou de comportamento laterítico, conforme afirmado em NOGAMI & VILLIBOR (1996).

Estima-se que cerca de 90% da área do estado de São Paulo é coberta por solos de comportamento laterítico e que já existam mais de 9000 km de rodovias construídas com bases de solos lateríticos e mais de dez milhões de metros quadrados de vias urbanas. A ampla ocorrência, associada às propriedades geotécnicas adequadas para a pavimentação, fez o uso desses tipos de solos atraente do ponto de vista econômico.

As vias desenvolvem-se ao longo de certas distâncias e assim atravessam regiões que, geralmente, apresentam constituições geotécnicas muito diversas quando comparadas entre si. Assim, torna-se necessário que se encontrem métodos que possibilitem a obtenção indireta dos parâmetros requeridos a partir de resultados de ensaios mais simples que pudessem ser realizados em grande número e rapidamente. Com esta finalidade foram criadas as classificações geotécnicas de solos, que permitem agrupar, a partir de ensaios mais simples e de rotina em qualquer laboratório, os diferentes materiais segundo categorias que apresentem características comuns.

O conhecimento dos solos tropicais que ocorrem na região é fundamental para pavimentação e, para isso, é necessário considerar-se sobretudo as suas peculiaridades de campo, tanto em condições naturais (cortes, subleito, fundações em geral), como após a apropriada compactação, quando então já integram o pavimento.

Ressalta-se que, no Brasil, o uso dos procedimentos tradicionais de estudo geotécnico como a HRB (*Highway Research Board*) e a USCS (*Unified Soil Classification System*), de origem estrangeira, não reconhece as peculiaridades dos solos tropicais e considera, muitas vezes, os de comportamento laterítico e não laterítico como tendo mesmas características, ainda que apresentem propriedades geotécnicas diferenciadas. As consequências do uso das classificações chamadas tradicionais em nosso meio técnico são o aumento dos custos dos pavimentos construídos além do rejeito de materiais de boa qualidade.

Em função dessas limitações surgiu a necessidade do desenvolvimento de métodos mais adequados para caracterizar e classificar os solos tropicais, para que seja possível prever seus comportamentos em obras de pavimentação. Para esta finalidade foi proposto o método MCT (Miniatura, Compactado, Tropical), desenvolvido por NOGAMI & VILLIBOR (1981), que mostra bem as diferenças entre os solos tropicais, conseguindo distingui-los.

Atualmente, estão surgindo estudos para classificar solos tropicais através de processos mais simples e rápidos quando comparado aos da Classificação MCT. O ensaio de adsorção de azul de metileno vem se mostrando eficiente e simples para a caracterização de solos tropicais. Esse ensaio é utilizado na França pelo *Laboratoire Central des Ponts et Chaussées* (LAN, 1977) para a caracterização e a classificação de solos.

No Brasil, estudos como os de CASANOVA (1986), FABBRI & SÓRIA (1991) e de PEJON (1992) confirmam que o ensaio de adsorção de azul de metileno é eficiente, rápido e simples para caracterizar solos tropicais. FABBRI (1994) realizou um estudo para caracterização de solos, utilizando parâmetros como a distribuição granulométrica e o ensaio de adsorção de azul de metileno pelo método da mancha para qualificar a fração fina dos solos. Os solos de comportamento laterítico apresentam um menor consumo azul de metileno (menor adsorção de corante) em relação aos de comportamento não laterítico.

Recentes estudos destacam-se na área de Engenharia de Transportes com a aplicação de Redes Neurais Artificiais (RNAs), como de CASSA & CUNHA NETO (1996), DYMINSKI & RIBEIRO (1996) e RODGHER *et al.* (1997). Esses trabalhos foram realizados para classificação e modelagem de materiais aplicados à construção civil, em especial à pavimentação (solos), com a utilização da técnica Redes Neurais Artificiais (RNAs), a fim de desenvolver uma maneira simples, rápida e econômica de avaliar o comportamento dos materiais. Essas pesquisas têm mostrado que as RNAs surgem como uma nova ferramenta que poderá fornecer alternativas de solução às convencionais já implementadas no campo da engenharia viária.

As Redes Neurais Artificiais (RNAs) são ferramentas computacionais fundamentadas nos princípios da Inteligência Artificial (IA) e potentes para solucionar problemas que envolvem reconhecimento de padrões, classificação e mapeamento. Dessa forma, as RNAs apresentam-se como uma nova técnica computacional alternativa ao sistema usual com mecanismos que permitem a entrada e saída de informações e o processo e assimilação dos conhecimentos contidos num universo de amostras, através do uso de componentes básicos como a representação, o raciocínio e o aprendizado.

O desenvolvimento das Redes Neurais Artificiais surgiu com o desejo de compreender o mecanismo de funcionamento do cérebro humano e copiá-lo. Pelo fato de basear-se no funcionamento do cérebro, as RNAs são formadas por grande número de unidades de processamento (nodos ou neurônios) conectados entre si (sinapses). Diferem dos modelos computacionais tradicionais por apresentarem propriedades e características particulares, tais como: adaptabilidade ou aprendizagem, capacidade de generalização, agrupamento e organização de dados e tolerância a falhas.

A aplicação de RNAs para solução de problemas em Engenharia Civil tem sido objetivo de inúmeros estudos. Os primeiros trabalhos científicos neste sentido começaram a se destacar no início da década de 1990, crescendo nos últimos anos.

Baseando-se nesses aspectos, desenvolveu-se esta pesquisa, cujo objetivo é aplicar a técnica das Redes Neurais Artificiais para a previsão de propriedades geotécnicas dos solos provenientes da área que compreende o município de São Carlos, baseada em outras propriedades determinadas preliminarmente. Esse método tem a finalidade de simplificar o processo de caracterização das propriedades peculiares dos solos, eliminando a lentidão dos procedimentos de ensaios e os cálculos a serem realizados, além de reduzir a dificuldade para fazê-los utilizando os métodos tradicionais.

Para atingir o objetivo, foram desenvolvidas 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 24 h 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 (V_a), coeficiente de atividade (CA), análise granulométrica por sedimentação do solo (peneiras #0,42, #0,074 e #0,005), parâmetros da classificação MCT (c' , P_i , d' e e') e classificação por cores (croma, valor e matiz). Além disso, também com a finalidade de estimar as propriedades tecnológicas dos solos, foram desenvolvidas equações de regressões múltiplas com os mesmos dados utilizados no treinamento das redes.

Cabe ressaltar que esse método proposto pode ser aplicado também a outras regiões brasileiras, uma vez que já se tem uma estimativa, com os resultados das simulações desse estudo, do número de amostras de solos necessárias para o treinamento e teste das RNAs e dos parâmetros mais adequados que alcançaram as RNAs satisfatórias para a região em estudo.

O método, apresentado nesse estudo, para previsão de propriedades geotécnicas dos solos aplicados à pavimentação urbana foi desenvolvido especialmente para cidades brasileiras de pequeno e médio portes com a finalidade de fornecer uma ferramenta que auxilie os projetos de pavimentos nas fases de caracterização do subleito e busca de materiais de empréstimos mais adequados.

1.2. ESTRUTURA DO TRABALHO

O presente trabalho consta de sete capítulos, incluindo as Considerações Iniciais (Capítulo 1) e doze anexos. O Capítulo 2 refere-se à revisão bibliográfica, apresentando um estudo de Redes Neurais Artificiais, sua concepção, sua evolução e alguns modelos de Redes Neurais Artificiais mais utilizados. O Capítulo 3 contém uma descrição dos estudos sobre as Aplicações de Redes Neurais Artificiais em Engenharia Civil, com ênfase à Engenharia de Transportes.

No Capítulo 4 é feito um levantamento bibliográfico sobre as Classificações Geotécnicas de Solos, descrevendo a classificação HRB (*Highway Research Board*), a Classificação MCT para solos tropicais, a utilização do ensaio de adsorção de azul de metileno pelo método da mancha na caracterização de solos e o emprego das cores na classificação de solos.

O Capítulo 5 aborda a metodologia aplicada ao estudo. Neste item, são apresentados uma descrição da área de estudo, dos materiais empregados e da coleta das amostras, assim como os métodos de trabalho para a obtenção dos resultados. No capítulo 6 é feita a apresentação e análise dos resultados. Finalmente, o sétimo capítulo apresenta as considerações finais e conclusões, sendo seguido pelas referências bibliográficas utilizadas na pesquisa.

O Anexo A é composto da localização das amostras, classe pedológica, classificação MCT e massa específica dos sólidos das amostras; o Anexo B da classificação de solos HRB (*Highway Research Board*); o Anexo C dos resultados do valor de azul (V_a), coeficiente de atividade (CA) e grau de atividade; o Anexo D da classificação de solos por cores (*Munsell Soil Color Charts*, 1975); o Anexo E da Classificação MCT e Granulometria; o Anexo F dos resultados dos ensaios de limite de liquidez e de plasticidade; o Anexo G do resumo das propriedades dos solos na umidade ótima para a energia normal e dos resultados dos ensaios de Mini-CBR, Expansão e Contração na Energia Normal; o Anexo H do resumo das propriedades dos solos na umidade ótima para a energia intermediária e dos resultados dos ensaios de Mini-CBR, Expansão e Contração na Energia Intermediária; o Anexo I da verificação da

concordância entre resultados previstos pela Classificação MCT e obtidos em laboratório, para as amostras estudadas; o Anexo J dos resultados das regressões lineares simples; o Anexo L dos resultados das Redes Neurais Artificiais e o Anexo M dos resultados das regressões múltiplas.

CAPÍTULO 2: REDES NEURAIS ARTIFICIAIS

O cérebro humano é o dispositivo mais complexo conhecido pelo homem. A capacidade de pensar, memorizar e resolver problemas tem levado muitos pesquisadores a buscar modelar sua estrutura e sua forma de processar informações. Um dos ramos da Ciência da Computação que estuda processos para produzir modelos computacionais que representem a funcionalidade do cérebro denomina-se Inteligência Artificial (IA).

Uma nova técnica que se enquadra em uma das sub-áreas da Inteligência Artificial de maior destaque na atualidade é a Rede Neural Artificial (RNA). As RNAs são modelos de processamento de informação inspirados em uma estrutura natural: o cérebro humano. Esses modelos não pretendem replicar a operação do cérebro, apenas utilizam como inspiração fatores conhecidos sobre o seu funcionamento, visando obter melhores desempenhos na resolução de problemas. Logo, os modelos neurais, procuram aproximar o processamento dos computadores ao cérebro. As RNAs possuem um grau de interconexões similar a estrutura do cérebro, um método que não é empregado em computadores convencionais, o que permite a uma rede neural realizar abstrações como “aprender”.

2.1. HISTÓRICO

A representação de neurônios e suas conexões sob forma matemática é uma nova técnica, conhecida como Redes Neurais Artificiais (RNAs) (ANN- do inglês *Artificial Neural Network*). Os primeiros estudos originaram-se dos conceitos obtidos por Aristóteles envolvendo cérebro humano (HERTZ *et al*, 1991). A partir da década de 40, iniciou-se o desenvolvimento teórico das RNAs, com trabalhos de

McCULLOCH & PITTS (1943) e HEBB (1949) *apud* HECHT-NIELSEN (1987)¹, que discutiam a capacidade de aprendizagem de informações das RNAs.

O primeiro modelo matemático de uma Rede Neural Artificial foi desenvolvido por McCULLOCH & PITTS em 1943. Tratava-se de um simples neurônio que trabalhava em um processo de decisão lógica (verdadeiro ou falso). O neurônio, nesse modelo, era composto de uma simples unidade de processamento, ativado pela soma ponderada das entradas e saídas computadas por uma função *threshold* bi-estável (0 ou 1). A combinação de várias unidades poderia, teoricamente, representar qualquer função lógica ou matemática.

HEBB, em 1949, apresentou uma teoria (*The Organization of Behavior*), que explica o processo de aprendizagem partindo do seguinte princípio: "Quando o axônio de uma célula está próximo o suficiente para excitar uma célula B e repetida e insistentemente toma parte na emissão de sinal elétrico da célula B, algum processo de crescimento ou mudança metabólica acontece em uma ou ambas as células tal que a eficiência de A, para fazer a célula B disparar, é aumentada."

ROSENBLATT (1958), *apud* RICH *et al.* (1994)², demonstrou que o neurônio de McCULLOCH & PITTS (1943) poderia ser treinado para resolver um problema linearmente separável, isto é, os conjuntos de classes podem ser separados por um hiperplano, em um número finito de etapas e o denominou de *Perceptron*.

WIDROW & HOFF (1960), *apud* CARVALHO (1997)³, desenvolveram o dispositivo Adaline (*Adaptive Linear Neurons*), um modelo utilizado como filtro de processamento de sinais.

MINSKY & PAPERT (1969) apresentaram uma análise detalhada das capacidades e limitações do *Perceptron*, e demonstraram que este pode resolver apenas problemas

¹ HECHT-NIELSEN R. (1987). *Theory of the backpropagation neural network*. Proc. IJCNN (Washington) DC, p.18-22.

² RICH, E.; KNIGHT, K.; SEJNOWSKI, T. S.; ROSENBERG, C. R. (1994) *Parallel Networks that learn to pronounce English Text*. *Complex Systems* 1:145.

³ CARVALHO, A. C. P. L. F. de (1997). Redes neurais artificiais. In: <http://www.iemsc.sc.usp.br/~andre/>, 15-03-97.

linearmente separáveis. Assim uma tarefa simples como aprender uma tabela lógica de um ou-exclusivo (XOR) não poderia ser realizada por um *Perceptron*.

Na década de 1970 e na primeira metade da década de 1980 ocorreram o desenvolvimento das pesquisas sobre RNAs alternativas. Entretanto, segundo CARVALHO (1997), destacam-se trabalhos como de KOHONEM (1972), sobre memória associativa e o de HOPFIELD (1984) com a aplicação de Redes Neurais Artificiais em problemas de otimização.

O desenvolvimento do algoritmo de treinamento *backpropagation*, por RUMELHART *et al.* (1986), mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Rede Neural Artificial mais utilizado atualmente as *Perceptron Multi-Layer* (MLP), treinadas com o algoritmo *backpropagation*. Estes autores tiveram o mérito de restaurar a confiança no *Perceptron*, o que permitiu um grande crescimento das pesquisas e aplicações das RNAs.

Numerosos avanços vêm sendo obtidos nos últimos anos no desenvolvimento de sistemas inteligentes, particularmente os que têm funcionamento inspirado nas redes neurais biológicas. Pesquisadores das mais variadas áreas (engenharia, economia, medicina, física, meteorologia, psicologia, química, entre outras) têm utilizado as Redes Neurais Artificiais (RNAs) para a solução dos diversos tipos de problemas, destacando-se a resolução dos problemas que envolvem dados incompletos e/ou com ruídos.

2.2. NEURÔNIO BIOLÓGICO

O cérebro humano é constituído de células chamadas neurônios. Os neurônios são células nervosas compostas por corpo celular ou soma, dendritos e axônio. A base do processamento realizado no cérebro humano segue as conexões existentes entre as estimadas 10^{11} células neurais, os neurônios, presentes em sua composição. O cérebro humano é formado por cerca de 100 bilhões de neurônios e mais de 100 trilhões de sinapses (conexões), possibilitando a formação de uma rede complexa.

Na Figura 2.1 observa-se o corpo celular ou soma, que é o centro dos processos metabólicos da célula nervosa. A partir deste, projeta-se uma rede de filamentos nervosos designados por dendritos e um longo filamento chamado axônio, que ramifica-se em filamentos e subfilamentos. Segundo KOVÁCS (1996), os dendritos cobrem um volume muitas vezes maior do que o próprio corpo celular e, por isso, por semelhança, formam uma árvore dendrital. O axônio, também referido como fibra nervosa, conecta a célula nervosa o outras do sistema nervoso.

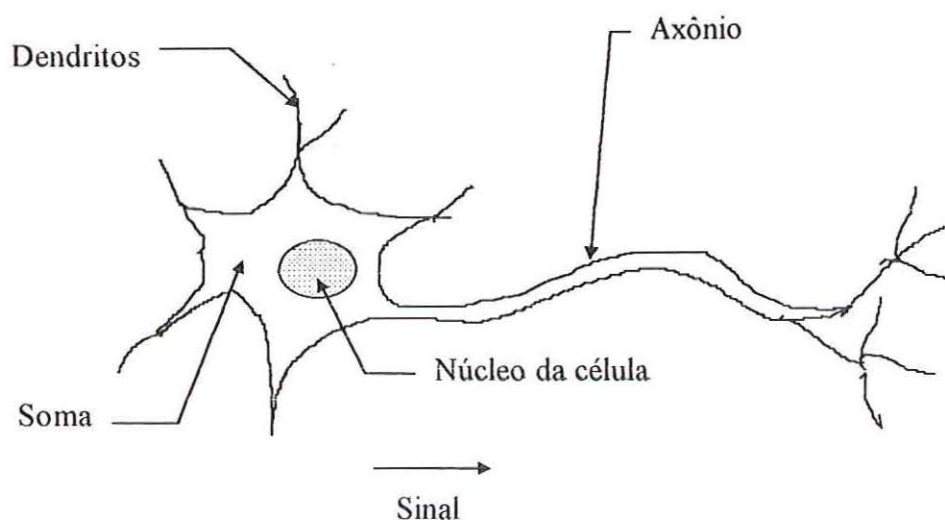


Figura 2.1 - Representação esquemática de um neurônio biológico.

Através de estudos realizados, o neurônio biológico passou a ser entendido como um dispositivo computacional do sistema nervoso, que possui muitas entradas e uma saída. As entradas ocorrem através das junções sinápticas ou sinapses que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como impulsos nervosos e constituem a informação que o neurônio processará de alguma forma para produzir como saída um impulso nervoso no seu axônio. A transmissão do sinal de uma célula para outra na sinapse é um processo químico complexo em que substâncias transmissoras específicas são liberadas no lado emissor da junção. A consequência é um aumento ou diminuição do potencial elétrico interior do corpo da célula receptora. Se este potencial alcançar um determinado limiar, um pulso, com intensidade e duração fixas, é enviado pelo axônio. A célula está ativa ou estimulada e o pulso é enviado

para as ramificações nas junções sinápticas de outras células. Caso contrário, a célula fica inibida.

2.3. REDES NEURAIS ARTIFICIAIS (RNAs)

As RNAs foram biologicamente inspiradas com a finalidade de imitar tarefas executadas pelo cérebro humano, funcionando de forma análoga ao neurônio biológico. Desta maneira são capazes de exibir uma série de características típicas do cérebro humano, como aprender por experiência, extrapolar informações de um exemplo para situações similares e selecionar informações relevantes dentro de um conjunto de dados.

Os tipos de tarefas que uma Rede Neural Artificial pode realizar são classificados, segundo JAIN *et al.* (1996), em sete grupos, a saber:

- a) Classificação de padrões: a tarefa consiste em relacionar um padrão de entrada com uma classe pré-definida (exemplo: dado um conjunto de índices físicos e uma classificação de solos tradicional, pode-se treinar a rede para reproduzir a classificação);
- b) Categorização: consiste em explorar similaridade entre padrões e agrupar padrões conhecidos, ou seja, um tipo de classificação de padrões não-supervisionada (exemplo: utilizando uma base de dados criar uma nova classificação de solos);
- c) Aproximação de funções: baseia-se em encontrar uma função que represente um conjunto de dados conhecidos, sendo que estes dados podem apresentar algum tipo de ruídos ou pequenos erros de leitura (exemplo: aproximar uma curva de tensão x deformação de uma rocha);
- d) Previsão: conhecido um conjunto de dados temporais, pode-se prever o próximo acontecimento (exemplo: dada uma seqüência de leituras de um instrumento de campo prever a próxima leitura);
- e) Otimização: a partir de um objetivo e restrições, encontrar, dentro do conjunto das soluções, a que melhor atende ao objetivo (exemplo: busca de superfície crítica na análise de estabilidade de taludes);

- f) Memória endereçável pelo conteúdo: um padrão é relacionado com ele mesmo, assim se este padrão estiver incompleto ou com ruído é possível reconstruí-lo (exemplo: conhecido o levantamento incompleto de um maciço rochoso de uma determinada região, pode-se levantar os dados que faltam ao levantamento);
- g) Controle: fundamenta-se em gerar uma instrução para que o sistema se comporte segundo um modelo de referência (exemplo: em uma escavação subterrânea com os dados da instrumentação, define-se como deve ser o avanço para que a escavação atenda a determinado padrão de segurança).

As RNAs são compostas por unidades de processamento simples (neurônios) que computam certas funções matemáticas; estas unidades são interligadas por um grande número de conexões (sinapses) associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada unidade da rede.

Uma RNA é formada, basicamente, por três componentes fundamentais: os neurônios artificiais – que são as unidades básicas de armazenamento de informações, a arquitetura – que armazena informações relativas aos relacionamentos entre os neurônios e o algoritmo de aprendizagem – que é utilizado para modificar o comportamento da rede com a intenção de adaptá-la a solucionar uma determinada tarefa.

O procedimento para a modelagem com o auxílio das RNAs, segundo DOWLA & ROGERS (1995), engloba inúmeras etapas. Primeiramente, a definição do problema a ser tratado (classificação, previsão, interpolação, extrapolação, etc ou a combinação deles). A partir disso, delinear as interações e processos, de modo a visualizar as relações entre dados de entrada e de saída, e estabelecer uma representação apropriada dos parâmetros que serão utilizados. A etapa seguinte é a concepção da rede, ou seja, definição do número de neurônios, da arquitetura, processo de aprendizagem e outros elementos. Finalmente mede-se o desempenho da rede, analisando sua sensibilidade.

PACHECO *et al.* (1995) observaram que o desempenho das RNAs é, em geral, avaliado em função de dois fatores determinantes:

1. Convergência: refere-se à capacidade das RNAs de aprenderem um determinado conjunto de dados definido no procedimento de treinamento. É ela que indica quando o procedimento é capaz de aprender a classificação definida nos padrões apresentados e sob que condições das redes;
2. Generalização: diz respeito à habilidade das RNAs reconhecerem padrões fora do conjunto de treinamento e é a principal propriedade que deve ser exigida de um sistema neural.

A idéia básica para a constituição de uma RNA envolve a possibilidade de “tomada de decisão” de um problema em estudo. A condição de se obter uma resposta a uma situação totalmente desconhecida e inesperada é uma das vantagens da utilização dessa técnica. Para que se possa garantir uma resposta desejada satisfatória, deve-se tentar encontrar uma arquitetura adequada para o problema e realizar o treinamento de forma eficiente. Cabe salientar que não apenas a forma como a RNA é treinada influi em seu desempenho, mas também a quantidade de casos utilizados em seu treinamento.

Segundo RICH & KNIGHT (1993) há porém algumas desvantagens apresentadas pela utilização das RNAs, entre elas:

1. A determinação da forma de treinamento. A rede pode necessitar de novos treinamentos, à medida que ocorre variação significativa no comportamento dos dados de entrada;
2. Não há garantias de se encontrar a melhor arquitetura possível;
3. Há dificuldade em definir os parâmetros da RNA, como por exemplo: taxa de aprendizagem.

Mas, ainda segundo RICH & KNIGHT (1993), apesar desses problemas, as vantagens resultam no grande atrativo que existe nas RNAs.

2.4. O MODELO COMPUTACIONAL DO NEURÔNIO

Existem inúmeras razões, segundo AGRAWAL (1995), para se desejar que computadores operem como cérebro humano, tais como:

1. A forma robusta como o cérebro opera; por exemplo, células cerebrais morrem a todo instante, porém o seu desempenho geral mantém-se inalterado;
2. O cérebro opera com instruções extremamente complexas e incompletas;
3. Tratamento especial para situações difusas, como, por exemplo, a possibilidade de recorrer a um “banco de dados” para tentar analisar uma situação inusitada;
4. É pequeno, compacto e despende pouca energia para seu funcionamento.

McCULLOCH & PITTS (1943) propuseram um modelo simples de um neurônio artificial, baseado no neurônio biológico. Esses neurônios artificiais possuem, na sua estrutura e funcionamento, uma similaridade grande com os neurônios biológicos. O neurônio artificial é uma unidade de processamento matematicamente simples, que recebe uma ou mais entradas e as transforma em saídas. Cada entrada tem um peso associado, determinando sua intensidade (TUBB, 1993).

O neurônio artificial é um dispositivo binário, cuja saída pode ser pulso ou não pulso. Descrito matematicamente como um modelo com n terminais de entrada $x_1, x_2, x_3, \dots, x_n$ (comparados aos dendritos) e com apenas uma saída y_k (representa o axônio). O comportamento das sinapses é estimulado através de pesos vinculados aos terminais de entrada, isto é, a x_1 é vinculado um peso w_{k1} , a x_2 um w_{k2} , ..., a x_n um w_{kn} . Os pesos podem assumir valores positivos ou negativos, dependendo do estado sináptico, se inibitório ou excitatório. O cálculo da saída do neurônio é realizado pelo somatório das entradas pelos respectivos pesos, positivos nos casos em que a sinapse é excitatória e negativos nos casos em que as sinapses são inibitórias.

Um neurônio biológico só terá o impulso executado quando a soma das duas entradas ultrapassar o seu limiar (*threshold*) de excitação. A ativação do neurônio artificial é realizada por meio de uma função de ativação, que ativa ou não a saída, dependendo do valor do somatório das entradas por seus respectivos pesos. A Figura 2.2, a seguir, mostra um esquema de neurônio artificial.

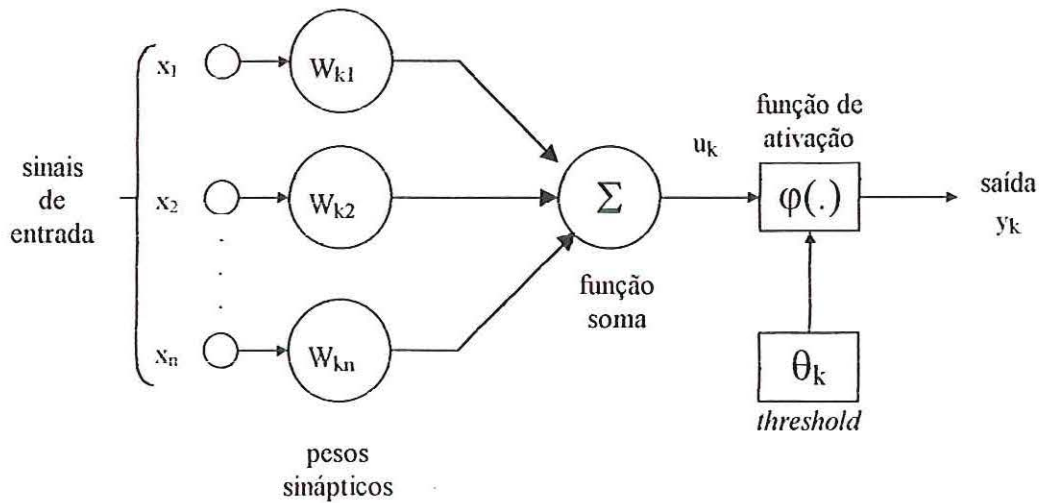


Figura 2.2: Modelo não-linear de um neurônio artificial, segundo HAYKIN (1994).

Os elementos básicos de um neurônio, apresentados na Figura 2.2, são:

- as sinapses, que são caracterizadas por um peso w , que pode representar a sua intensidade. O papel do peso w_{kj} é multiplicar o sinal x_j na entrada da sinapse j , conectada ao neurônio k . O peso w_{kj} é positivo se a sinapse associada é excitatória e negativo, se inibitória;
- um somatório, que adiciona as entradas ponderadas pelos respectivos pesos, ou seja,

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

- um limiar (*threshold*), θ_k , que tem um papel determinante na saída do neurônio. Se o valor de u_k for menor que este limiar, então, a saída do neurônio fica inibida. Caso contrário, o neurônio fica ativo;
- uma função de ativação, φ , que funciona como um limitante à amplitude da saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, comumente $[0, 1]$ ou $[-1, 1]$;
- a saída do neurônio, y_k , onde:

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

Em geral, o valor do *threshold* é aplicado com a inclusão de uma entrada x_0 igual a -1 e um peso w_{k0} igual ao valor θ_k . Portanto, a nova entrada da função de ativação, já incluindo o limiar, é dada por:

$$v_k = \sum_{j=1}^n w_{kj} \cdot x_j - \theta_k \quad (2.3)$$

2.5. FUNÇÕES DE ATIVAÇÃO

HAYKIN (1994) afirma que a função de ativação define o valor da ativação de um neurônio conforme o nível de atividade da entrada. As funções de ativação típicas trabalham com adição, comparação ou transformações matemáticas. Algumas das funções de ativação mais comuns são:

(a) Função linear: $\varphi_i(t+1) = v_i(t)$;

(b) Função *threshold* ou limiar: $\varphi_i(t+1) = \begin{cases} 1, & \text{se } v_i(t) \geq \theta \\ 0, & \text{se } v_i(t) < \theta \end{cases}$

(c) Função *piecewise* linear: $\varphi_i(t+1) = \begin{cases} +1, & \text{se } v_i(t) > \theta \\ -\theta \leq v_i(t) \leq \theta \\ -1, & \text{se } v_i(t) < -\theta \end{cases}$

(d) Função sigmóide logística: $\varphi_i(t+1) = \frac{1}{(1 + e^{-v_i(t)})}$

As Figuras 2.3 e 2.4 apresentam as funções de ativação mais comuns.




Figura 2.3: Funções de ativação linear e *threshold* ou limiar.




Figura 2.4: Funções de ativação *piecewise* linear e sigmóide logística.

2.6. ARQUITETURA E TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS

Os neurônios de uma rede são conectados formando a arquitetura. Geralmente, as arquiteturas são classificadas em dois tipos, de acordo com a organização das camadas consideradas:

1. Rede com uma camada: forma mais simples de arquitetura, caracterizando-se por uma camada de sinais de entrada e por um conjunto de neurônios de saída. A direção do fluxo de sinais na rede ocorre apenas em um sentido. A camada de

- entrada não é considerada como uma camada de neurônios, pois não ocorre nenhum tipo de processamento. Um exemplo de rede com uma camada pode ser a arquitetura *Perceptron* (Figura 2.5).
2. Rede com multicamadas: caracteriza-se pela presença de uma ou mais camadas intermediárias. A função dos neurônios das camadas intermediárias é a de “interferir” entre o sinal externo e a saída. A adição de uma ou mais camadas de neurônios proporciona à RNA a capacidade de responder mais satisfatoriamente ao conjunto de dados. Não existem regras para a definição do número de unidades intermediárias. Constitui exemplo deste tipo de rede a arquitetura *Multilayer Perceptron* (Figura 2.6).

A topologia é definida em função dos tipos de conexões. Cada conexão entre dois neurônios possui um peso associado formando a topologia da rede. Baseado no padrão de conexões a rede pode ser agrupada em duas classes, a saber:

1. Redes *Feedforward* (tipo mais comum): no padrão de conexões entre os neurônios não existem *loops*, isto é, as conexões são unidirecionais e a propagação segue uma única direção. Nas redes *feedforward* é comum que os neurônios sejam dispostos em camadas. Um neurônio de uma camada pode ou não ser conectado com todos os neurônios das camadas seguintes;
2. Redes Recorrentes: o padrão de conexões admite a existência de *loops*, as conexões podem ser bidirecionais e a propagação ocorre em dois sentidos.

2.7. TIPOS DE APRENDIZAGEM

No contexto das RNAs, o processo de aprendizagem pode ser visto como o problema de determinação dos pesos das conexões, de forma que a rede fique apta a realizar uma tarefa específica. Uma rede neural “aprende” a partir de um conjunto de padrões disponíveis e, o processo de aprendizado ocorre melhorando com o tempo o desempenho da rede atualizando, de forma iterativa, os pesos das conexões. Um dos atrativos das RNAs é exatamente a sua capacidade de aprender do seu ambiente (por exemplos) e melhorar seu desempenho.

Segundo Carvalho *et al.* (1998), denomina-se algoritmo de aprendizado um conjunto de regras bem definidas para a solução de um problema de aprendizado, que são específicos para determinados modelos de RNAs e que diferem entre si pela forma com que os modelos são atualizados.

Os paradigmas do aprendizado definem a forma como a rede se relaciona com o ambiente. HAYKIN (1994) divide os paradigmas do aprendizado em três grupos, a saber:

1. Aprendizado supervisionado: caracterizado pelo conhecimento exato da resposta que está associada a cada padrão de entrada. Em problemas de classificação, a classe a que o padrão de entrada pertence é conhecida. Se a associação é completamente conhecida então é facilitada a definição do erro (o menor erro quadrático, por exemplo) associada à resposta. Isto gera a possibilidade de comparar o desempenho (resposta calculada ou real) com a resposta pré-definida (desejada), mudando a aprendizagem na direção em que o erro diminui;
2. Aprendizado não-supervisionado: não há informação sobre o objetivo do aprendizado; tudo que é aprendido é consequência da regra de aprendizado obtida dos dados de treinamento, denominado como auto-organização. É geralmente utilizado para detectar regularidade de dados;
3. Aprendizado por reforço: uma combinação dos dois paradigmas anteriores. No aprendizado por reforço cada padrão está associado a uma informação (como na aprendizagem supervisionada) mas esta informação é restrita e formada apenas por uma declaração, para a resposta associada ao padrão, do tipo “resposta boa” ou “resposta ruim”. O algoritmo de aprendizagem deve conseguir realizar as mudanças apenas com este tipo de informação.

2.8. TIPOS DE REDES NEURAIIS ARTIFICIAIS

Apresenta-se, a seguir, alguns modelos de Redes Neurais Artificiais mais utilizados. Inicialmente são apresentados os modelos *Perceptron*, *Adaline* e *Perceptron Multi-Layer* (MLP), por serem redes simples. Os demais modelos (Redes Base Radial, Kohonen e Hopfield) foram selecionados buscando englobar, de forma simples, as RNAs que têm aplicação na engenharia civil.

2.8.1. PERCEPTRON

A rede *Perceptron* utiliza o modelo neural de McCULLOCH & PITTS, conforme Figura 2.5, com uma camada de entrada e uma camada de saída. Todas as entradas são ponderadas pelo vetor de pesos das conexões. Os neurônios de saída utilizam uma função de ativação *threshold* (Figura 2.3b). A camada de entrada é responsável pela extração de características dos padrões e a de saída é a camada de discriminação com uma unidade de saída para discriminar padrões de entrada.




Figura 2.5: Topologia de um *Perceptron* simples com uma única saída.

A regra de aprendizagem do *Perceptron* é supervisionada. Consiste em uma estratégia intuitiva de mudança nos pesos caso o padrão seja classificado erroneamente, isto é, se a ativação da unidade de saída, para um dado padrão de entrada, não for igual à classe correta do padrão.

$$\Delta w_i = \begin{cases} x_i & \text{se classe} = 1 \\ -x_i & \text{se classe} = 0 \end{cases} \quad (2.4)$$

A rede *Perceptron*, conforme Figura 2.6, é utilizada para a classificação de padrões linearmente separáveis (ROSENBLATT, 1958). Esta regra de aprendizagem apresenta a seguinte propriedade: “Se todas as classes são linearmente separáveis, os pesos vão convergir para valores que representem matematicamente esta separação”.

2.8.2. MODELO ADALINE

O modelo ADALINE, segundo CARVALHO (1997), utiliza a regra sugerida por WIDROW & HOFF (1960), também conhecida como Regra Delta. No lugar da função de ativação *threshold*, do *Perceptron*, é utilizada a função linear (isto é, a ativação da unidade de saída é igual à soma ponderada das entradas).

O treinamento é supervisionado com o algoritmo de aprendizado Regra Delta, o ajuste dos pesos é realizado considerando a distância entre a saída e a resposta desejada. Estas redes resolvem apenas problemas linearmente separáveis, pois não têm camada intermediária, desta forma mapeiam entradas semelhantes em saídas semelhantes.

2.8.3. PERCEPTRON MULTI-LAYER (MLP)

O *Perceptron* de uma camada apresenta limitações, mostradas por MINSKY & PAPERT no final da década de 1960, como a incapacidade de solucionar problemas que não sejam linearmente separáveis. Contudo, com o desenvolvimento do algoritmo de treinamento *backpropagation*, por RUMELHART *et al.* (1986), precedido por propostas semelhantes ocorridas nos anos 70 e 80, mostrou-se que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizado atualmente, as redes *Perceptron MultiLayer* (MLP), treinadas com o algoritmo *backpropagation*.

Neste novo modelo são inseridas uma ou mais camadas entre a entrada e saída, como mostra a Figura 2.6. Estas camadas, denominadas de camadas intermediárias, consistem em unidades de processamento com funções de ativação não-lineares, tipicamente a função sigmóide (Figura 2.4d). O número de camadas intermediárias depende da complexidade do problema a ser analisado, não há uma regra básica. Para encontrar a melhor arquitetura (número de camadas e neurônios por camada) é necessário pesquisar a que apresentar melhor eficiência entre as implementadas.

Na MLP, a camada de entrada apresenta os padrões à rede, a camada de saída recebe os estímulos da camada intermediária (escondida) e constrói o padrão que será a

resposta. As camadas intermediárias extraem as características dos padrões apresentados e seus pesos são codificações destas características, permitindo, assim, que a rede adquira sua própria representação do problema.

O algoritmo de aprendizagem *backpropagation* do *Perceptron MultiLayer* também é denominado de Regra Delta Generalizada. Em uma rede não treinada, quando apresentado um padrão, o resultado obtido não coincide com o esperado, pode-se assim definir uma função erro. A Regra Delta Generalizada permite minimizar o erro, modificando os pesos das conexões, por meio de uma retropropagação. Este algoritmo opera basicamente em duas fases, conforme mostra a Figura 2.6, cada uma percorrendo a rede em um sentido, a saber:

1. Fase *forward*: ocorre quando os sinais de entrada são fornecidos à rede e esta produz uma saída. Esta saída é comparada com a saída desejada e o erro para cada neurônio da camada de saída é calculado;
2. Fase *backward*: se processa a partir da última camada, é quando cada neurônio procura ajustar seus pesos de maneira a reduzir seu erro. Nesta fase a rede procura ajustar seus pesos baseando-se no erro admissível.

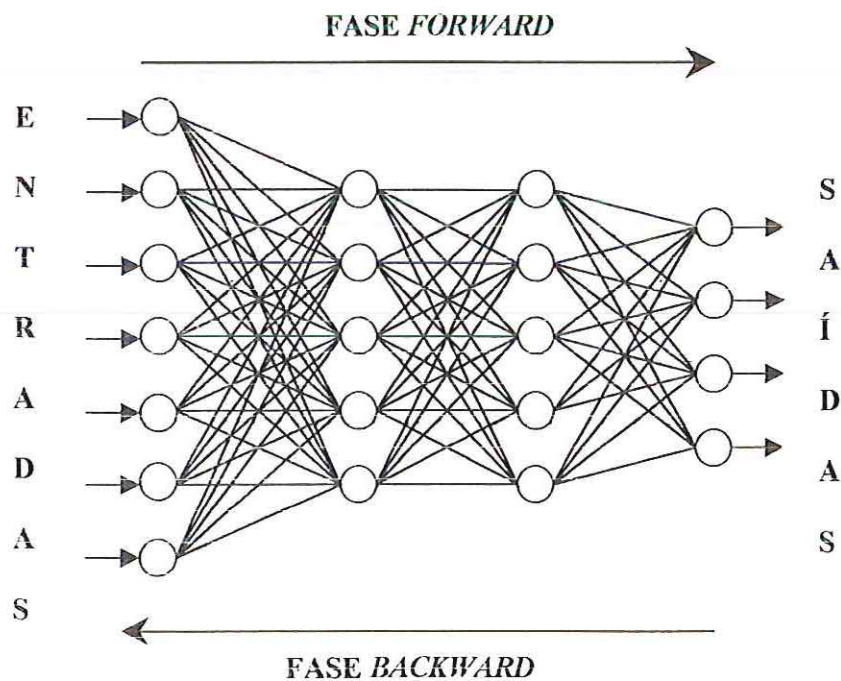


Figura 2.6 – Rede *Perceptron MultiLayer* (MLP), treinadas com o algoritmo *backpropagation*.

Seja E_p , a função erro para o padrão p , t_{pj} , o valor da saída desejado (para o padrão p e o nó j), y_{pj} , o valor da saída obtido e w_{ij} , o peso do nó i para o nó j . Assim, a função E_p pode ser dada pela expressão (2.5).

$$E_p = \frac{1}{2} \sum_j (t_{pj} - y_{pj})^2 \quad (2.5)$$

O erro médio total é dado pela média dos erros de todos os padrões.

A atualização dos pesos é dada pela adição de um termo de variação a eles (Δw_{ij}), ou seja, para um peso w_{ij} , o seu peso atualizado será dado por:

$$w_{ij}(t+1) = w_{ij} + (\Delta w_{ij}) \quad (2.6)$$

sendo:

$$\Delta w_{ij} = \eta x_i y_j (1 - y_j) \delta_j$$

$$\delta_j = (t_j - y_j), \text{ para a última camada}$$

$$\delta_j = \sum_k w_{jk} \delta_k, \text{ para as camadas intermediárias.}$$

A variável η é denominada taxa de aprendizado. Seu valor determina a suavidade que se dará à atualização dos pesos. Se η for grande, o valor de Δw_{ij} será grande e, conseqüentemente, os pesos sofrerão uma alteração mais brusca.

A atualização dos pesos inclui mais uma variável, o *momentum* (α), que pode aumentar a velocidade de aprendizado e se caracteriza por acelerar o treinamento em regiões planas da superfície de erro, diminuindo o problema de instabilidade da rede. Com a adição do *momentum*, Δw_{ij} será dado por:

$$\Delta w_{ij}(t+1) = \eta x_i y_j (1 - y_j) \delta_j + \alpha (w_{ij}(t) - w_{ij}(t-1)) \quad (2.12)$$

A atualização dos pesos pode ser realizada de duas formas: por padrão (*on-line*) ou por ciclo (*batch*). Na atualização por padrão os pesos são atualizados após a apresentação de cada padrão e, na atualização por ciclo os pesos são atualizados após a apresentação de todos os padrões.

O algoritmo *backpropagation* pode apresentar problemas durante o treinamento da rede. Quando a superfície for muito complexa, o treinamento ocorre lentamente, a rede pode incidir num mínimo local. Pode ocorrer, também, o *overfitting*, quando a rede depois de um certo tempo de treinamento memoriza os padrões que já foram apresentados, em vez de generalizá-los.

2.8.4. REDE DE FUNÇÕES BASE RADIAIS (*RADIAL BASIS FUNCTIONS*)

Em determinados tipos de problemas é interessante considerar a distância dos padrões ao protótipo de uma classe no espaço de características. Portanto, pode-se usar uma função base radial de ativação. A arquitetura de uma rede de funções base radiais é do tipo *feedforward* multicamadas com uma camada escondida e, possui como função de ativação as funções linear e Gaussiana. A função base radial é centrada em um ponto especificado pelo vetor de pesos associado com a unidade. A unidade é ativada caso o padrão esteja na vizinhança de um ponto associado a esta unidade. Todas as posições e distâncias destes núcleos são aprendidas a partir dos padrões de treinamento. Cada unidade de saída implementa uma combinação linear destas funções de base radial. Do ponto de vista da aproximação de funções, as unidades escondidas compõem um conjunto de funções que constituem o conjunto base para representação dos padrões de entrada no espaço medido pelas unidades escondidas (BEALE & JACKSON, 1990).

Existem inúmeros algoritmos de aprendizagem para as redes de funções base radiais, geralmente utiliza-se um paradigma de aprendizagem híbrido, que estima a posição e as distâncias dos núcleos utilizando um algoritmo não-supervisionado; em seguida, por um algoritmo supervisionado, baseado nos métodos dos mínimos quadrados, determina-se os pesos das conexões entre a camadas escondida e a de saída. Pode-se empregar algoritmo não iterativo para refinar os parâmetros da rede quando as unidades da camada de saída são lineares.

O algoritmo de aprendizagem híbrido das funções base radiais converge mais rápido que o algoritmo *backpropagation* do MLP. Porém, em muitos problemas, as funções base radiais exigem um grande número de unidades escondidas, o que implica num

tempo maior de execução (após o treinamento) nas redes em relação a rede MLP. Cabe ressaltar que a maior eficiência das redes com funções base radiais ou do MLP depende do tipo de problema a ser tratado.

As redes Funções Base Radiais são aplicadas em reconhecimento de caracteres e alvos, processamento de sinais e voz. Dentre as aplicações na área de classificação financeira, uma das mais bem sucedidas é a análise de créditos. A análise de créditos pode envolver tanto pessoa física (cartão de crédito, cheque especial, empréstimo pessoal), como pessoa jurídica.

2.8.5. REDES DE KOHONEN

Existem aplicações onde é desejável que a rede faça sua própria classificação dos dados de treinamento. Nesses tipos de problemas podem ser utilizadas redes auto-organizativas (Redes *Self-organising*), onde as redes definem seus parâmetros por si próprias (sem auxílio externo), descobrem padrões característicos nos dados de entrada e por fim formam sua própria classificação dos dados de treinamento.

As redes de KOHONEN são inspiradas no funcionamento biológico do cérebro de animais superiores, onde regiões do cérebro estão associadas com determinadas funções. A rede é composta basicamente de uma matriz de unidades de processamento, cada qual conectada com n unidades de entrada. Cada neurônio calcula a distância Euclidiana entre o vetor de entrada, x e o seu vetor de pesos, w .

A rede de KOHONEN utiliza um tipo especial de aprendizagem competitiva (todos os neurônios competem entre si e apenas o vencedor e seus vizinhos têm seus pesos incrementados) que define uma vizinhança espacial para cada unidade de saída. A vizinhança pode ter diferentes formatos (quadrado, retangular ou circular). Após o treinamento a rede forma agrupamentos que devem ser rotulados para indicar a classe que representam e permitirem as classificações.

Estas redes têm aplicações em áreas como reconhecimento de voz, classificação de sinais de radar, controle de braços de robôs, modelagem do cérebro e tratamento de água.

2.8.6. REDE DE HOPFIELD

As redes de HOPFIELD foram desenvolvidas por HOPFIELD em 1982, *apud* CARVALHO (1997)⁴, e sua função primária é recuperar um padrão armazenado na memória em resposta à apresentação de uma versão incompleta ou com ruído daquele padrão.

A rede de HOPFIELD consiste num dado número de neurônios, cada um conectado com todos os outros (não existem nós de entrada ou de saída, ou seja, todos os nós têm o mesmo papel). Esta característica representa a principal limitação da rede, pois a falta de neurônios escondidos faz com que as representações internas não aprendam dos padrões de treinamento.

A rede apresenta pesos simétricos, isto é, o peso que liga dois neurônios é o mesmo em ambos os sentidos. Cada nó possui um *threshold* e uma função de ativação do tipo binário (0,1) ou bipolar (-1,+1). A ativação é calculada como somatório das entradas, ponderada através dos pesos, e subtraída do *threshold*.

A ativação de todas as unidades é calculada de forma iterativa, utilizando a função de ativação. A rede deverá convergir para um estado estável dependendo das entradas externas e dos pesos.

A rede de HOPFIELD é utilizada para armazenamento de padrões e problemas de otimização. Em problemas de armazenamento de padrões, se for apresentado um padrão incompleto, previamente armazenado, a rede pode reconstituir este padrão.

⁴ CARVALHO, André C. P. L. F. de (1997). Redes neurais artificiais. In: <http://www.icmsc.sc.usp.br/~andre/>

CAPÍTULO 3: APLICAÇÕES DE REDES NEURAIIS ARTIFICIAIS NA ENGENHARIA CIVIL

3.1. INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) têm demonstrado ser uma alternativa econômica e eficiente nas mais variadas áreas práticas da indústria, comércio, medicina e engenharia.

A aplicação de Redes Neurais Artificiais (RNAs) para solução de problemas em Engenharia Civil tem sido objetivo de inúmeros estudos. Os primeiros trabalhos científicos neste sentido começaram a se destacar no início da década de 1990, crescendo nos últimos anos. Estes estudos envolvem aplicações em classificação de solos, planejamento dos transportes, estabelecimento de correlações, prospecção, geotecnia ambiental, estabilidade de taludes, fundações, dentre outros. Neste capítulo são apresentadas algumas aplicações nas mais variadas áreas de Engenharia Civil, em especial na Engenharia de Transportes.

3.1.1. CLASSIFICAÇÃO E PREVISÃO DO COMPORTAMENTO DE MATERIAIS DE CONSTRUÇÃO

ZHANG *et al.* (1991) utilizaram uma rede *Perceptron MultiLayer* (MLP) para relacionar mineralogia, tamanho e forma do grão, densidade e porosidade com a deformabilidade de um arenito, obtendo resultados satisfatórios.

A maioria das classificações tradicionais dos solos baseiam-se em índices físicos: índice de plasticidade (IP), limite de liquidez (LL) e distribuição granulométrica. CAL (1995) desenvolveu uma rede neural para classificação de 20 amostras de argilas

utilizadas na China. Neste trabalho foi utilizado um *Perceptron MultiLayer* (MLP) de três camadas, sendo a camada de entrada com três neurônios que representavam o índice de plasticidade, a umidade de saturação e a porcentual de argila. A camada escondida era composta de oito unidades e a camada de saída composta de 6 neurônios, que representavam as seis possíveis classificações (na notação do autor: *heavy clay, light clay, heavy sub-clay, medium sub-clay, light sub-clay e sub-sand*). O conjunto de treinamento era composto de seis padrões e a rede foi testada com outros 20 padrões. A rede classificou todos os padrões corretamente. Para o autor, a classificação de solos por redes neurais é eficaz e abre a possibilidade de considerar outros fatores, como por exemplo a origem do solo.

Uma rede neural, desenvolvida por GOH (1995), para estimar a condutividade hidráulica de *liners* de argila de aterros sanitários, utilizou uma base de dados que compreende informações de aterros sanitários da América do Norte. Nesse trabalho, a rede foi treinada com 31 padrões e testada com 16. A camada de saída da rede era composta por um neurônio, que representava a condutividade hidráulica e a camada escondida era composta por 3 unidades. Para a camada de entrada testou-se diferentes combinações na composição. O modelo estudado que apresentou os melhores resultados era composto por sete unidades na camada de entrada: índice de plasticidade (IP), porcentagem de pedregulho, porcentagem de argila, grau de saturação inicial na compactação, peso do compactador (kN), limite de liquidez (LL) e porcentagem de finos.

Os resultados obtidos nesse estudo foram então comparados com um modelo de regressão proposto por BENSON *et al.* (1994) para a mesma base de dados. Observou-se que a rede tem seus pontos mais próximos da linha de igualdade (medido=previsto) e que os coeficientes de correlação da rede são mais próximos da unidade que os da correlação convencional.

Este tipo de aplicação, segundo GOH (1997), envolve a busca de uma arquitetura para a rede que melhor descreva o problema. Isto implica tanto na escolha do número

de unidades de entrada e saídas como na otimização do número de unidades escondidas. A definição das entradas e saída envolve o conhecimento da física do problema. Quanto ao número de unidades escondidas, existem técnicas para definir seu número ótimo, porém estas técnicas não estão bem estabelecidas e o processo de tentativa e erro é o caminho mais utilizado.

A condutividade hidráulica de *liners* de argila foi também modelada através de duas redes neurais por NAJJAR & BASHEER (1996), usando a mesma base de dados de GOH (1995). A primeira rede testada apresentava uma camada de entrada composta por todos os parâmetros disponíveis: índice de plasticidade (IP), limite de liquidez (LL), atividade (ACT), porcentagem de pedregulho, porcentagem de areia, porcentagem de argila, porcentagem de finos, umidade de compactação, peso específico aparente seco (DD), tipo do compactador (pé de carneiro ou compactador de pneus) e peso do compactador (kN). O tipo de compactação era definido para a rede através de duas variáveis que recebiam o valor 0 ou 1, dependendo do equipamento utilizado em campo. Os resultados da rede foram considerados satisfatórios, apresentando um coeficiente de correlação $R^2=0,92$.

A segunda rede estudada possuía na camada de entrada os parâmetros IP, porcentagem de pedregulho, porcentagem de argila, grau de saturação inicial na compactação e peso do compactador (kN). Foi comparado o desempenho desta segunda rede com a regressão e os resultados da rede neural foram melhores.

AGGRAWAL *et al.* (1994) apresentaram estudos com redes que avaliam o ângulo de atrito e a coesão de um silte argiloso a partir do peso específico seco e da umidade, chegando a boas conclusões.

CASSA & CUNHA NETO (1996) mostraram a aplicabilidade das RNAs como técnica de previsão de algumas propriedades de materiais usados em pavimentação, como por exemplo, a resistência à compressão do concreto a partir de dados experimentais de resistências a baixas idades (01 e 07 dias) e as resistências à flexão

da pasta de cimento comum (sem aditivos) a partir da composição destes. Os resultados obtidos demonstraram a utilidade da RNA como técnica de previsão das propriedades de sistemas complexos, produzindo modelos com boa precisão de maneira rápida e simples.

Foi modelado por ELLIS *et al.* (1995) o comportamento de uma areia num ensaio triaxial. Na camada de entrada da rede estavam representadas a tensão efetiva normal, a deformação, a pressão neutra no tempo i ; a tensão confinante, a densidade relativa inicial e o coeficiente de uniformidade. Os parâmetros da camada de saída da rede eram representados pela tensão efetiva normal e a pressão neutra no tempo $i+1$. A rede reproduziu e previu os ensaios, sendo que os resultados da previsão da curva tensão *versus* deformação foram melhores do que os da curva de pressão neutra *versus* deformação.

A simulação por redes neurais do comportamento de um solo residual, em ensaio de cisalhamento direto, com o solo na umidade natural, foi descrita por DYMINSKY & RIBEIRO (1995). A rede utilizada era composta de três unidades de entrada que representavam a tensão normal, o índice de vazios inicial e o deslocamento horizontal adimensional. A camada de saída foi representada apenas pela tensão cisalhante e, na camada escondida, foram utilizados 10 neurônios. O autor concluiu que a rede apresentou bons resultados para os ensaios empregados tanto no treinamento como nos testes.

As técnicas de redes neurais também têm-se mostrado uma boa alternativa para a modelagem do comportamento de materiais. O comportamento tensão-deformação do solo residual gnáissico foi analisado por DYMINSKI *et al.* (1996) utilizando-se duas redes neurais, uma para o estado submerso e outra para o não submerso. Os resultados, apesar do número ainda limitado de condições consideradas, mostraram que as redes neurais podem ser aplicadas com diversas vantagens no estudo do comportamento dos solos.

RODGHER *et al.* (1997) apresentaram um estudo para a aplicação da técnica das redes neurais artificiais para previsão da classe MCT (NOGAMI & VILLIBOR, 1981) dos solos pertencentes às regiões tropicais. O estudo utilizou ensaios mais simples como a adsorção de azul de metileno pelo método da mancha e a análise granulométrica por peneiramento para prever se o solo era de comportamento laterítico ou não (L - laterítico e N - Não laterítico) e à qual das sete subclasses da classificação MCT pertence (NA, NA', NS', NG', LA, LA', LG'). As previsões obtidas pela RNA foram comparadas com os resultados obtidos pela classificação MCT de solos para 2 classes (L e N) apresentando um grau de acerto de 87,8%, e para 7 classes (NA, NA', NS', NG', LA, LA', LG'), com um desempenho de 82,4%. Concluíram que a utilização das Redes Neurais Artificiais é promissora na caracterização de solos tropicais, permitindo estabelecer uma boa concordância entre os resultados produzidos pela RNA e os fornecidos pela classificação MCT (Miniatura, Compactado, Tropical).

3.1.2. CONSTRUÇÃO E MANUTENÇÃO DE PAVIMENTOS

Com relação à área de infra-estrutura dos transportes, um dos trabalhos pioneiros foi o de PANT *et al.* (1993), que usaram as RNAs para verificar a preparação de superfícies em pavimentos flexíveis, alcançando bons resultados.

KASEKO & RITCHIE (1993) empregaram uma integração entre RNA e técnicas convencionais de processamento de imagem para detectar fissuras na superfície de pavimentos rodoviários. A metodologia desenvolvida foi capaz de classificar a superfície do pavimento fissurado pelo tipo, severidade e extensão das fissuras detectadas em imagens de vídeos. Os resultados da pesquisa demonstraram a possibilidade dessa nova técnica de detectar, classificar e quantificar superfícies fissuradas em pavimentos rodoviários.

FWA & CHAN (1993) compararam o desempenho das RNA com diversos índices subjetivos utilizados em um sistema de gerência de pavimentos (*defecting rating index, pavement condition index, maintenance control index e maintenance needs*

index). Os autores concluíram que as RNAs apresentaram um procedimento que simula mais rigorosamente o processo de avaliação prioritária da manutenção de pavimento do que esses índices. Os exemplos utilizados no estudo sugerem que o uso de RNAs têm algumas vantagens sobre os índices, tais como: não exigem do operador a especificação subjetiva da relação funcional entre as avaliações prioritárias e as condições do pavimento e a atualização das RNAs para refletir as mudanças em políticas de manutenção ou práticas de construções é conceitualmente séria e fácil de ser executada.

ATTONH-OKINE (1994) utilizou as RNA para determinar a irregularidade longitudinal (*roughness*) na superfície de pavimentos flexíveis, verificando que as RNAs apresentaram mais vantagens do que os métodos estatísticos tradicionais, sendo capaz de aprender sobre as imperfeições do pavimento apenas baseando-se nos dados coletados de experiências passadas.

ELDIN E SENOUCCI (1994) discutiram o uso de *Perceptron Multi-Layer* (MLP) com algoritmo *backpropagation* como uma ferramenta para gerenciamento para a manutenção de pavimento de concreto articulado. Nessa pesquisa propuseram que a utilização RNAs têm vantagens sobre os outros métodos de avaliação de condição de pavimento e concluíram que as RNAs:

- a) oferecem um procedimento sistemático que simula mais rigorosamente o processo subjetivo de avaliar a condição de manutenção do pavimento;
- b) são capazes de aprender adequadamente a partir dos exemplos de treinamento;
- c) mostram boa qualidade de generalização, sendo capazes de predizer condições de avaliações;
- d) indicam uma boa qualidade de tolerância a ruídos, pois são capazes de fornecer as mesmas condições de avaliação, com um nível de confiança de 95,0%, quando fornecido um conjunto de entradas com imperfeição.

MEIER & RIX (1994) apresentaram um procedimento de retroanálise com o *Falling Weight deflectometer* (FWD) para pavimentos flexíveis de três camadas com o auxílio

de RNAs. Segundo os autores, as RNAs apresentaram como principal vantagem a velocidade de processamento dos dados, inserido as RNAs no universo para a estimativa dos módulos resilientes por retroanálise.

Com o objetivo de desenvolver uma metodologia baseada em RNA para o processamento de imagens de vídeos para detecção automatizada, classificação e quantificação de fissuras de pavimentos, KASEKO *et al.* (1995) fizeram uma avaliação comparativa entre a classificação tradicional e a realizada por intermédio das RNAs, obtendo ótimos resultados com o uso das redes neurais.

OWUSU-ABABIO (1995) desenvolveu um modelo de rede neural artificial para a seleção de estratégias ótimas de manutenção de pavimentos flexíveis. A melhor RNA implementada classificou erroneamente, nos resultados do conjunto de validação, seis casos dos cem testados.

TAHA & HANNA (1995) desenvolveram, com o auxílio de algoritmo genético, um modelo neural para a seleção das melhores estratégias para manutenção de pavimentos flexíveis. O melhor resultado atingido pela rede implementada, classificou erroneamente somente seis casos dos cem estudados.

A AASHO (*American Association of State Highway Officials*) conduziu, durante o período de 1958 a 1960, um experimento rodoviário (*AASHO Road Test*), que considerou as espessuras das camadas, a carga por eixo e o tipo de eixo como variáveis primárias. Os dados obtidos foram processados utilizando-se técnicas estatísticas tradicionais. BANAN & HJELMSTAD (1996) reexaminaram os resultados do *AASHO Road Test* usando um modelo de redes neurais desenvolvido por eles e denominado MC-HARP. Os resultados mostraram que esse modelo, quando comparado com as análises tradicionais, pode representar melhor os dados da AASHO. Os autores concluíram também que o MC-HARP pode ser uma ferramenta apropriada para o desenvolvimento de modelos de desempenho de pavimentos.

IONNIDES *et al.* (1996) utilizaram RNAs para avaliar as ligações dos pavimentos de concreto dos três maiores aeroportos dos Estados Unidos. Essa avaliação apresentou uma economia significativa de recursos com a aplicação de RNAs.

SHIKOURY & MARTINELLI (1996) utilizaram RNAs para classificar condições de concretos utilizados em pavimentos rígidos (deflectivos e não deflectivos) com base no processamento de ondas sonoras. As redes propostas foram capazes de reconhecer os tipos e as condições dos concretos.

RANDOLPH (1996) propôs uma RNA para determinar o número de rodovias e custo diário de operações para manutenção de vias. PHANT *et al.* (1996) compararam a técnica de *Delphi*, utilizada para determinar ações a serem tomadas na manutenção de pavimentos urbanos, com as RNAs. As redes foram implementadas com os resultados do método *Delphi* e apresentaram comportamento semelhante. Os autores concluíram que não existia mais a necessidade de se utilizar a técnica de *Delphi* para o caso, bastaria que as RNAs fossem treinadas com resultados provenientes da técnica.

BREGA (1996) utilizou Redes Neurais Artificiais para avaliar o estado do pavimento e apoiar as decisões dentro de um sistema de gerência de pavimentos. Ele apresentou um método para a avaliação da condição em pavimentos flexíveis, utilizando *Perceptron Multi-Layer* (MLP) com o algoritmo *backpropagation*. Para caracterização da condição dos pavimentos foram utilizados o índice de gravidade global (IGG) e a irregularidade longitudinal. Os experimentos demonstraram que as redes neurais simulam satisfatoriamente os estados dos pavimentos.

FWA *et al.* (1996) desenvolveram um modelo computacional (PAVENET-R) baseado em algoritmo genético para solucionar problemas de manutenção e reabilitação de pavimentos com o auxílio de redes neurais. Apresentaram um programa detalhado de soluções para manutenção e reabilitação, analisando também a característica de convergência de cada solução.

CHOU & LIAU (1996) estudaram algoritmos automatizados para avaliar as condições do pavimento. Os objetivos do trabalho eram desenvolver segmentação de imagens, classificar os métodos para isolar os principais defeitos e modelar uma RNA para reconhecer trincas em blocos, remendos, trincas longitudinais, transversais e do tipo jacaré. Os estudos apresentaram uma taxa de acerto em torno de 93%.

FLINTSCH *et al.* (1996) pesquisaram o uso de RNAs para a seleção de projetos de reabilitação de pavimentos e constataram que os resultados são promissores para selecionar os projetos, assim como para indicar possíveis avaliações de manutenção de pavimentos.

RODGHER & ODA (1997) realizaram um trabalho que trata da previsão de defeitos nas estradas não-pavimentadas através da utilização de Redes Neurais Artificiais (RNAs) com base nos fatores que influenciam a formação dos defeitos (características geotécnicas, climáticas, geométricas e de tráfego). Os dados utilizados foram obtidos de um trabalho de campo do município de São Carlos-SP, onde foi aplicado um método de avaliação das condições da superfície de rolamento, que avaliou mais de 100 km de estradas não-pavimentadas. Neste estudo a utilização da técnica de RNAs mostrou-se promissora para a previsão de defeitos em estradas não-pavimentadas, podendo proporcionar meios econômicos para identificar os vários tipos de defeitos. Verificou-se que, através de fatores que influenciam a formação de defeitos, como o tráfego, as condições climáticas, o tipo de solo e a rampa (%), foi possível prever os tipos de defeitos com uma taxa de acerto de 88,67%, sem haver necessidade de fazer o levantamento dos defeitos no campo, o que pode resultar numa economia de tempo e profissionais especializados, indispensáveis quando da utilização do método de avaliação dos defeitos da superfície de estradas não-pavimentadas.

RODGHER *et al.* (1998) propuseram um método alternativo para a seleção de atividades de manutenção e reabilitação de estradas não-pavimentadas utilizando a técnica de RNAs. O método tem como base os fatores que influem na formação dos defeitos (características geotécnicas, climáticas, geométricas e tráfego) e utiliza dados

coletados em levantamento de campo (tipo de solo, rampas, tráfego e tipos de defeitos) realizado no município de São Carlos-SP. Nesse estudo, as RNAs demonstraram ser soluções mais simples, tecnicamente versátil e rápida, sem a necessidade de entendimento completo do método convencional para a seleção de atividades de manutenção e reabilitação de estradas não-pavimentadas. Um número reduzido de dados experimentais disponíveis foi utilizado para treinar e testar seis redes. Ainda assim, os resultados apresentados comprovam a possibilidade de utilização das RNAs nessa área de estudo. Cabe ressaltar que as seis redes treinadas apresentaram, pelo menos, um “melhor desempenho” igual a 100%. Isso deve-se, possivelmente, ao fato do problema em estudo ter um nível pequeno de complexidade.

COUTINHO NETO *et al.* (1999) apresentaram um procedimento para retroanálise de pavimentos flexíveis compostos de três camadas (capa, base e subleito) utilizando Redes Neurais Artificiais (RNAs). A retroanálise é um processo de obtenção dos módulos resilientes das camadas do pavimento a partir da bacia de deflexão medida no campo e de um sistema computacional iterativo para análise estrutural de pavimentos. Para o procedimento de retroanálise proposto foi implementada uma RNA composta por uma camada de entrada com 13 neurônios: a bacia de deflexão artificial (10 deflexões), raio de curvatura (R) e as espessuras da capa ($e_{\text{capa}} = 5$ a 30 cm) e da base ($e_{\text{base}} = 15$ a 75 cm). A camada de saída é composta de 3 neurônios, correspondentes aos módulos de resiliência da capa, base e subleito. Para o conjunto de treinamento das RNAs utilizou-se o *ELSYM5* para criar 1200 bacias de deflexões hipotéticas de um pavimento flexível. Através de regressões lineares entre os módulos reais (*ELSYM5*) e os previstos pela RNA, obtiveram-se coeficientes de determinação (R^2) iguais a 0,704, 0,887 e 0,989, respectivamente para capa, base e subleito. Estes coeficientes demonstram uma boa correlação linear entre os módulos reais (*ELSYM5*) e os previstos (RNA). Com os resultados concluiu-se que as RNAs são ferramentas promissoras para serem utilizadas como procedimento de retroanálise para pavimentos flexíveis.

COUTINHO NETO (2000) investigou um procedimento para retroanálise de pavimentos flexíveis utilizando RNAs. Nesta pesquisa foram utilizadas 35472 bacias de deflexões hipotéticas, criadas pelo programa ELSYM5. A base de dados de treinamento das RNAs consistiu dessas bacias de deflexão e dos módulos e espessuras que as geraram. A camada de entrada das RNAs foi composta da(s) espessuras(s) da(s) camada(s) do pavimento, da bacia de deflexão (na simulação com a viga *Benkelman*, além desses parâmetros, incluiu-se o raio de curvatura (R)) e a camada de saída foi composta pelos módulos resilientes das camadas do pavimento. No estudo foi utilizado o *Perceptron Multi-Layer* (MLP) com o algoritmo *backpropagation*. Para o procedimento de retroanálise proposto foram implementadas seis RNAs: duas simulando o procedimento para pavimento de duas camadas (uma simulando o ensaio da viga *Benkelman* e a outra a do *Falling Weight Deflectometer*), duas para pavimento de três camadas (simulação com os mesmos aparelhos) e duas para pavimento de quatro camadas (simulando os ensaios descritos anteriormente). Mediante as regressões lineares entre os módulos reais (ELSYM5) e os previstos (RNA), obtiveram-se coeficientes de determinação (R^2) e erros médios relativos (EMR). Estes parâmetros demonstraram uma boa correlação linear entre os módulos reais (ELSYM5) e os previstos (RNA), e o autor concluiu que as RNAs são ferramentas potentes para serem utilizadas como procedimento de retroanálise para pavimentos flexíveis de duas, três e quatro camadas.

3.1.3. PLANEJAMENTO DOS TRANSPORTES

As Redes Neurais Artificiais estão sendo aplicadas, também, ao planejamento e operação dos transportes, onde são observados trabalhos como os de NAKATSUJI & KAKU (1991), FAGHRI & HUA (1992a e 1992b) e TAYLOR & DEIRDRE (1994). Essas aplicações apresentaram estudos relacionados com geração de viagens, diagnóstico e controle de congestionamentos, transporte de materiais perigosos e controle de tráfego aéreo.

Segundo FAGHRI & HUA (1992a), no campo de projeto geométrico de vias, pode-se aplicar as RNAs em desenho geométrico de vias, definição de terminais e estações,

demanda, determinação de condições climáticas, rodovias inteligentes e transporte público urbano.

Com a utilização de redes MLP treinadas com o algoritmo de *backpropagation*, SMITH & DEMETSKY (1992) previram o fluxo de tráfego a curto prazo comparando-o com uma abordagem mais tradicional. Concluíram que o modelo usando algoritmo de *backpropagation* foi claramente superior, embora o modelo tradicional obtivesse um resultado adequado para prever futuros volumes de tráfego.

HUA & FAGHRI (1993) propuseram um sistema neural artificial para classificar os sinais de tráfego sobre pavimento (sinalização horizontal). Segundo os autores as RNAs são ferramentas promissoras para tarefas orientadas pelo homem e pelo computador. O uso de RNAs para a automatização do sistema de classificação de sinais de tráfego, que atualmente é realizado pelo homem, torna o sistema apto de corrigir a variância de julgamento do inspetor, assim como acelera o processo completo para uma grande quantidade de classificações. O êxito desse sistema conduz a várias aplicações, como por exemplo, o gerenciamento de repintura dos sinais ser totalmente automatizado

FLOOD & KARTAM (1994a e b) mostraram como as Redes Neurais Artificiais podem ser aplicadas em diferentes problemas de engenharia civil, tais como: mapeamento, modelagem de processos dinâmicos, otimização e para detectar acidentes de tráfego rodoviário. HSIAO *et al.* (1994) aplicaram RNAs e Lógica *Fuzzy*, com respeitáveis desempenhos.

Para simular a avaliação de áreas problemáticas em sinalização de intersecções de alta velocidade, HUANG & PANT (1995) fizeram estudo de casos com redes neurais. Determinaram uma zona de conflito, área onde o motorista, visualizando a luz amarela, decide se pára ou segue na intersecção, tomando como base três tipos de comportamentos observados: passar no sinal vermelho, parar bruscamente e acelerar no amarelo. Compararam os modelos obtidos com dados de campos coletados de

várias intersecções (baixo volume e alta velocidade), mostrando que as RNAs foram eficientes para a previsão de acidentes.

IVAN *et al.* (1995), baseando-se na concentração, velocidade e fluxo observado em uma via, apresentaram um algoritmo baseado em RNAs para a associação destes dados para determinar a probabilidade de ocorrer ou não incidentes. Assim, reduzindo de forma sensível a margem de erro caracterizada nos alarmes falsos, que são resultados, principalmente, da observação humana. Os índices de acertos das RNAs foram maiores que os obtidos pelos controladores de tráfego tradicionais.

O potencial para o uso combinado de métodos e técnicas típicos de pesquisa operacional (OR) e inteligência artificial (IA) realizados na área de engenharia de planejamento de transporte, com referência particular ao controle de tráfego rodoviário são discutidos por BIELLI & REVERBERI (1996), mostrando os novos desafios para a comunidade científica.

VUKADINOVI *et al.* (1996) estabeleceram um processo para otimização do uso de linhas de trens suburbanos comparando os roteiros estabelecidos pelos encarregados com os simulados pelas RNAs. As RNAs foram treinadas para elaborar os roteiros com base nas atividades realizadas pelos encarregados na organização dos horários dos trens.

WEI *et al.* (1996) mostraram a aplicabilidade das RNAs na classificação de veículos através do processamento de imagens. Os experimentos realizados, neste estudo, apresentam as taxas de precisão de reconhecimento de veículos pesados, carros e motocicletas como sendo de, respectivamente, 98,5%, 96,2% e 91,9%.

FURTADO (1998) apresentou um método para avaliação e ordenamento de alternativas de projetos de transportes aplicando RNAs. O método baseia-se na idéia de que uma RNA pode simular os recursos da inteligência humana sendo possível treiná-la para o reconhecimento de "padrões de avaliação". Na aplicação do método,

utilizou-se um grupo de projetos americanos. O autor concluiu que os resultados da aplicação do método demonstraram que as RNAs, quando convenientemente treinadas, podem simular o papel dos especialistas na avaliação e ordenamento das alternativas para projetos de transportes.

BRONDINO (1999) utilizou as RNAs para fins de avaliação de imóveis e estudou a influência de uma medida de acessibilidade no valor de terrenos urbanos. A utilização de redes neurais forneceu estimativas adequadas de valor, verificando-se através dela que a acessibilidade tem um peso superior a 34% no valor final.

3.1.4. GEOTECNIA

Uma análise da distribuição espacial de estabilidade de talude foi realizada por XU & HUANG (1994). A abordagem dada ao problema assemelha-se à das classificações geomecânicas de maciços rochosos. Um total de quatorze características, que influem na estabilidade, foram levantadas pelos autores e utilizadas como entradas da rede, e o talude recebeu uma classificação entre cinco níveis de estabilidade estabelecidos pelos autores que corresponderam às saídas da rede. Foi empregado uma camada intermediária de dez neurônios. A rede foi treinada com 10 padrões e testada com outros dez padrões, sendo capaz de classificar corretamente as classes de estabilidade.

GOH *et al.* (1995) treinaram uma rede para prever o máximo deslocamento horizontal em escavações escoradas, utilizando resultados de diversas simulações através de elementos finitos. A rede apresentava como parâmetros de entrada a largura da escavação (m), a razão entre espessura do solo e largura da escavação, a rigidez do muro (MNm^2/m), a altura da escavação (m), a resistência ao cisalhamento não-drenada (kPa), a razão entre o módulo de elasticidade não-drenado e a resistência não-drenada e o peso específico do solo (kN/m^3). Na camada de saída, uma unidade representava o máximo deslocamento horizontal (m). Concluíram que a vantagem do emprego de RNA, nesse caso, está no fato que, depois de treinada a rede, o tempo de geração da entrada e de processamento da rede é muito inferior ao da análise por

elementos finitos. A utilização da rede torna-se bastante encorajadora, principalmente em análises preliminares.

Para a previsão da capacidade de carga de fundações emprega-se fórmulas empíricas e semi-empíricas. As redes neurais surgem como uma nova ferramenta para elaboração deste tipo de correlação. LEE & LEE (1996), utilizando dados da literatura, treinaram e testaram uma rede MLP que relacionava a capacidade de cargas de estacas cravadas com a relação comprimento sobre diâmetro. O máximo erro na previsão da capacidade de carga não excedeu 25%.

A identificação dos perfis de alteração de solos é uma informação fundamental em investigações geotécnicas visando a ocupação dos terrenos. O uso da técnica de avaliação do terreno se constitui em uma ferramenta bastante útil para este reconhecimento. Porém, o processo de interpretação de fotografias aéreas pode se tornar bastante lento quando se trata de avaliar grandes parcelas do terreno. Com o objetivo de agilizar o processo, LOLLO & ZUQUETTE (1996) discutiram o uso de RNAs como mecanismo de identificação das feições de relevo. Concluíram que a técnica de avaliação do terreno pode se constituir em uma boa alternativa para o levantamento de perfis de alteração de solos, associando esses materiais com feições do relevo, e tornando esse levantamento mais ágil e de menor custo.

3.1.5. HIDRÁULICA E SANEAMENTO

Uma Estação de Tratamento de Esgotos (ETE) deve funcionar de forma correta para não acarretar problemas tanto do ponto de vista social, quanto do ponto de vista biológico. HANISCH *et al.* (1996) apresentaram um estudo de modelagem de uma ETE utilizando RNAs, visando a previsão dos parâmetros de operação, apoiados em informações passadas. O modelo de previsão proposto utilizando RNAs mostrou-se bastante promissor na modelagem de sistemas biológicos de tratamento de esgotos.

BALLINI (1996) apresentou um estudo sobre a adequabilidade de se usar os modelos de RNAs conhecidos como *Kohonen* e *Perceptron Multi-Layer* (MLP) com o

algoritmo *Backpropagation*, na previsão de chuva/vazão de uma bacia hidrográfica. Os modelos de precipitação/vazão procuram simular parte do ciclo hidrológico, ou seja, através da precipitação conhecida como bacia hidrográfica, o modelo simula as vazões que ocorreram no passado sem registro, ou que ocorrerão no futuro breve. Utilizou-se os dados, já existentes, da Bacia Hidrográfica do Rio Atibaia em um período de observação de 1971 à 1983. Observou-se, nos testes realizados, que a Rede *Perceptron Multi-Layer* (MLP) apresentou um desempenho superior à Rede *Kohonen* para previsão chuva/vazão.

CAPÍTULO 4: CLASSIFICAÇÕES GEOTÉCNICAS DE SOLOS

A caracterização das propriedades mecânicas e hidráulicas dos solos é um dos fatores mais importantes que influem na escolha do solo como material de construção em obras viárias, pois dependem da caracterização aspectos determinantes relacionados ao custo de construção e manutenção de uma estrada. Assim, é indispensável que se avalie, preliminarmente, as propriedades geotécnicas dos solos.

Para que uma classificação de solos seja conveniente para engenharia, segundo SÓRIA (1985), deve apresentar duas características importantes: permitir que, quando se tem um grande número de amostras, se ensaiem apenas alguns poucos solos que representem o universo das amostras em questão; permitir que, tendo-se a classe do solo, tenha-se uma estimativa do seu comportamento no campo ou na obra; isto além de facilitar a comunicação entre técnicos que conheçam a mesma classificação.

Neste capítulo, faz-se uma breve apresentação da classificação tradicional HRB (*Highway Research Board*) e Classificação MCT (miniatura, compactado, tropical); a utilização do ensaio de adsorção de azul de metileno pelo método da mancha na caracterização de solos e a utilização das cores na classificação de solos.

4.1 A CLASSIFICAÇÃO HRB

A classificação do HRB (*Highway Research Board*), originária do *Bureau of Public Roads* (BPR) de 1929, conforme PARREIRA (1995), é uma das mais empregada, no Brasil, na caracterização de solos para uso em rodovias. Nesta classificação, os solos são subdivididos em grupos e subgrupos, de acordo com os critérios baseados em granulometria e plasticidade.

No sistema HRB os solos são subdivididos em materiais granulares e materiais siltosos e argilosos, conforme a quantidade de material que passa na peneira de nº 200 (0,074 mm), seja menor ou maior a 35%, respectivamente. Os solos granulares compreendem os grupos A-1 (subdivididos em A-1-a e A-1-b), A-2 (subdivididos em A-2-4, A-2-5, A-2-6 e A-2-7), e A-3. Os solos siltosos e argilosos pertencem aos grupos A-4, A-5, A-6 e A-7 (subdivididos em A-7-5 e A-7-6), conforme Tabela 4.1.

Segundo PARREIRA (1995), o procedimento da classificação é simples, executam-se ensaios de granulometria por peneiramento e limites de liquidez (LL) e de plasticidade, devendo-se determinar também o chamado índice de grupo (IG), que é um número inteiro variando de 0 a 20 e que, de acordo com essa classificação, define a capacidade de suporte do terreno de fundação de um pavimento. Quanto menor for o IG melhor será o solo, de modo que o valor 0 (zero) indica um material excelente e o valor 20 (vinte) um péssimo material para subleito. O IG é dado pela expressão:

$$IG = 0,2a + 0,005ac + 0,01bd \quad (4.1)$$

onde:

a = porcentagem do material que passa na peneira nº 200, menos 35; se essa porcentagem for maior que 75, adota-se a = 40 e, se é menor que 35, adota-se a = 0;

b = porcentagem do material que passa na peneira nº 200, menos 15; se essa porcentagem for maior que 55, adota-se b = 40 e, se é menor que 35, adota-se b = 0;

c = valor do limite de liquidez, menos 40; se o limite de liquidez for maior que 60%, adota-se c = 20 e, se é menor que 40%, adota-se c = 0;

d = valor do índice de plasticidade, menos 10; se o índice de plasticidade for maior que 30%, adota-se d = 20 e, se é menor que 30%, adota-se d = 0.

A partir dos dados de granulometria, limite de liquidez, índice de plasticidade, conforme PARREIRA (1995), consulta-se a Tabela 4.1, sempre da esquerda para direita, e obtém-se o grupo a que pertence o solo ensaiado. Caso o solo se enquadre no grupo A-7, deve-se verificar se ele pertence ao subgrupo A-7-5 ou A-7-6. Se IP for menor ou igual a LL menos 30, pertence ao subgrupo A-7-5; caso o IP seja maior que LL menos 30, deverá ser classificado como A-7-6.

Tabela 4.1 – Classificação de solos da HRB, adaptada de ASTM (1990), segundo PARREIRA (1995).

CLASSIFICAÇÃO GERAL	MATERIAIS GRANULARES (35% ou menos passando na peneira nº 200)							MATERIAIS SILTOSOS E ARGILOSOS (mais de 35% passando na peneira nº 200)			
	A-1		A-3	A-2				A-4	A-5	A-6	A-7
GRUPOS	A-1-a	A-1-b		A-2-4	A-2-5	A-2-6	A-2-7				A-7-5
Porcentagem que passa nas peneiras nominal igual a											
2,00 mm	50 máx	-	-	-	-	-	-	-	-	-	-
0,42 mm	30 máx	50 máx	51 mín	-	-	-	-	-	-	-	-
0,074 mm	15 máx	25 máx	10 máx	35 máx	35 máx	35 máx	35 máx	36 mín	36 mín	36 mín	36 mín
Características da fração que passa na peneira nominal igual a 0,42 mm											
Limite de liquidez (%)	-	-	-	40 máx	41 mín	40 máx	41 mín	40 máx	41 mín	40 máx	41 mín
Índice de plasticidade (%)	6 máx	6 máx	NP	10 máx	10 máx	11 mín	11 mín	10 máx	10 máx	11 mín	11 mín
Índice de Grupo (IG)	0	0	0	0	0	<4	<4	<8	<12	<16	<20
Materiais predominantes	Pedra britada, pedregulho e areia		Areia fina	Areia e areia siltosa ou argilosa				Solos siltsos		Solos argilosos	
Comportamento geral como subleito	Excelente a bom							Regular a mau			

4.2. CLASSIFICAÇÃO MCT PARA SOLOS TROPICAIS

4.2.1. INTRODUÇÃO

As classificações tradicionais de solos, que baseiam-se na distribuição granulométrica, nos valores de limite de liquidez (LL) e no índice de plasticidade (IP), como a HRB (*Highway Research Board*) e a USCS (*Unified Soil Classification System*), foram desenvolvidas principalmente nos Estados Unidos e na Europa, onde prevalecem tipos de solos e ambientes climáticos bem diferentes daqueles encontrados no Brasil. Desta forma, essas classificações tornam-se ineficientes para a previsão de propriedades dos solos pertencentes às regiões tropicais impedindo o aproveitamento racional dos solos predominantes no Brasil e dificultando a solução de problemas geotécnicos rodoviários podendo resultar num aumento considerável do custo da pavimentação.

Segundo VILLIBOR *et al.* (1996), o uso de métodos tradicionais utilizados na identificação e classificação dos solos tropicais pode ocasionar duas consequências:

1. Se o solo classificado comportar-se bem melhor que o previsto, pode-se desperdiçar pelo superdimensionamento o pavimento;
2. Se o solo classificado comportar-se pior que o previsto, pode-se reduzir a vida útil do pavimento ou ocorrer a sua ruptura precoce.

NOGAMI & VILLIBOR (1980) mostraram, experimentalmente, que solos tropicais lateríticos e não lateríticos, que possuem propriedades geotécnicas diferentes, podem pertencer à mesma classe, segundo esses métodos tradicionais (HRB e USCS-AASHO). Assim, por exemplo, muitos solos arenosos finos lateríticos utilizados como bases de pavimentos com desempenho satisfatório, podem ser classificados no grupo A-6, e nessas condições, seriam considerados de má qualidade como subleito, mesmo quando compactados apropriadamente, à luz das classificações tradicionais.

No Simpósio Brasileiro de Solos Tropicais, realizado em 1981, foi proposto por NOGAMI & VILLIBOR (1981) uma “Uma Nova Classificação de Solos para Finalidades Rodoviárias” denominada MCT (Miniatura, Compactado, Tropical),

onde são apresentadas duas classes de solos, segundo sua origem pedogenética, e sete grupos, e os ensaios são realizados em corpos de prova de dimensões reduzidas (50 mm de diâmetro nominal).

Ainda segundo NOGAMI & VILLIBOR (1981), o desenvolvimento da classificação MCT auxiliou na solução de problemas relacionados ao emprego de solos em obras de engenharia rodoviária, pois baseia-se nas considerações climáticas e nos materiais existentes nas regiões tropicais.

4.2.2. A CLASSIFICAÇÃO MCT

Para se classificar um solo pela MCT, utiliza-se o ensaio mini-MCV, que foi adaptado do ensaio do MCV (*Moisture Condition Value*) de Parsons (1976), por SÓRIA & FABBRI (1980), e o ensaio de perda de massa por imersão, proposto por NOGAMI & VILLIBOR (1981).

A classificação geotécnica MCT (Miniatura, Compactado, Tropical), desenvolvida por NOGAMI & VILLIBOR (1980, 1981, 1985), reúne os solos tropicais, de acordo com o seu comportamento no estado compactado, em duas classes principais: solos de comportamento laterítico (L) e solos de comportamento não laterítico (N). Os solos de comportamento laterítico são subdivididos em três subclasses: areias lateríticas (LA), solos arenosos lateríticos (LA') e solos argilosos lateríticos (LG'), enquanto os de comportamento não laterítico são subdivididos em quatro subclasses: areias não lateríticas (NA), solos arenosos não lateríticos (NA'), solos siltosos não lateríticos (NS') e solos argilosos não lateríticos (NG'). O ábaco da classificação MCT é mostrado na Figura 4.1.

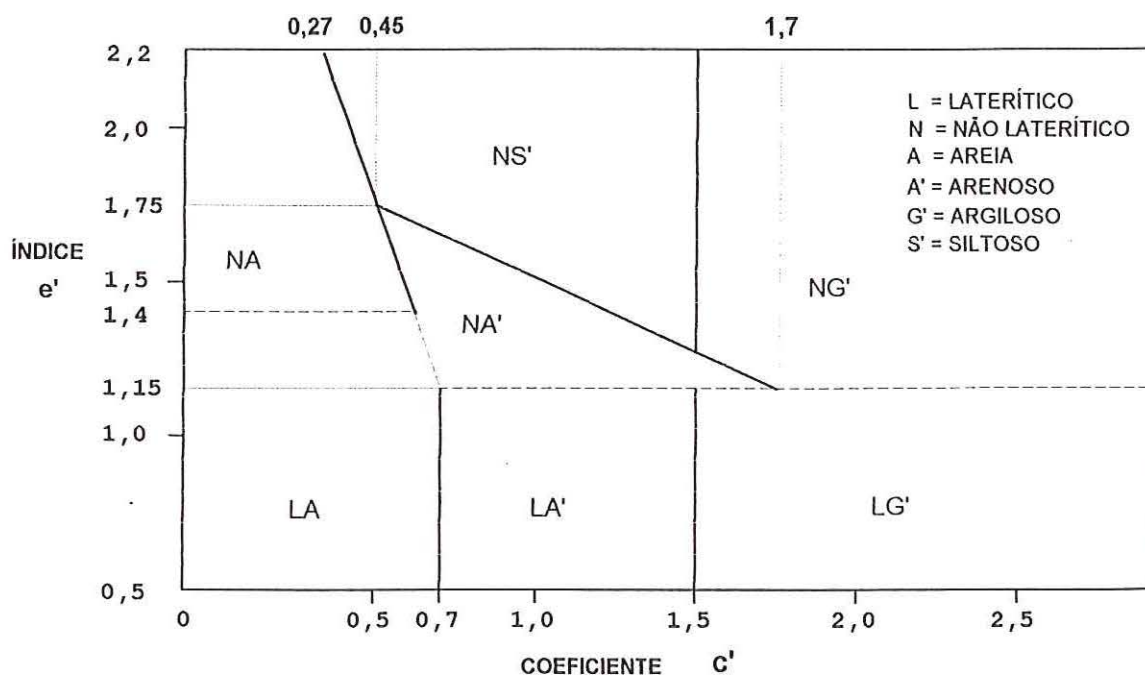


Figura 4.1 – Ábaco da classificação MCT (NOGAMI *et al.*, 1993).

Para utilizar a classificação MCT são necessários dois índices obtidos dos ensaios de laboratório (Mini-MCV e Perda de peso por imersão). O primeiro, coeficiente c' , que traduz a argilosidade do solo em análise, obtido do ensaio de Mini-MCV e corresponde à inclinação da curva de diferença de altura *versus* o índice Mini-MCV, para o valor do índice Mini-MCV igual a 10 (expresso em mm). Nos casos onde o ensaio não fornece uma curva para o índice Mini-MCV igual a 10 ou 15, deve-se fazer a devida interpolação para a obtenção desse parâmetro.

O segundo índice necessário para a classificação MCT, índice e' que expressa o caráter laterítico do solo, é calculado segundo a seguinte expressão:

$$e' = \sqrt[3]{\frac{20}{d'} + \frac{P_i}{100}} \quad (4.1)$$

onde:

d' : coeficiente angular da parte mais inclinada do ramo seco da curva de compactação correspondente a 12 golpes, expresso em $\text{kg/m}^3\%$;

P_i : Perda de peso característica do solo, determinada segundo a massa específica (altura) obtida para o índice Mini-MCV igual a 10, durante o ensaio de Mini-MCV, expressa em %.

Através desses dois índices pode-se classificar o solo analisado, utilizando-se o ábaco apresentado na Figura 4.1. A Tabela 4.2 apresenta as classes da Classificação MCT, a previsão das propriedades geotécnicas dos solos em função de cada uma dessas classes e a sua adequação para obras rodoviárias.

Tabela 4.2 – Valores das propriedades dos solos em função da classe MCT (NOGAMI *et al.*, 1993).

COMPORTAMENTO		N = NÃO LATERÍTICO				L = LATERÍTICO			
Grupo	MCT	NA	NA'	NS'	NG'	LA	LA'	LG'	
Propriedade	MINI CBR Sem Imersão	M,E	E	M,E	E	E	E,E	E	
	Com Imersão	M,E	M,E	B,M	E	E	E	E	
	EXPANSÃO	B	B	E	M,E	B	B	B	
	CONTRAÇÃO	B	B,M	M	M,E	B	B,M	M,E	
	COEF. PERMEABIL. (k)	M,E	B	B,M	B,M	B,M	B	B	
	COEF. SORÇÃO (S)	E	B,M	E	M,E	B	B	B	
Utilização (ordem de preferência)	Base de Pavimento	NR	4 ^o	NR	NR	2 ^o	1 ^o	3 ^o	
	Reforço do Subleito	4 ^o	5 ^o	NR	NR	2 ^o	1 ^o	3 ^o	
	Subleito Compactado	4 ^o	5 ^o	7 ^o	6 ^o	2 ^o	1 ^o	3 ^o	
	NR: Não	Aterro Compactado	4 ^o	5 ^o	6 ^o	7 ^o	2 ^o	1 ^o	3 ^o
	Recomen-	Proteção à Erosão	NR	3 ^o	NR	NR	NR	2 ^o	1 ^o
	dade	Revestimento Primário	5 ^o	3 ^o	NR	NR	4 ^o	1 ^o	2 ^o
Corpos de prova compactados na massa específica aparente seca máxima próxima da energia normal		Mini-CBR (%)		E (%)	C (%)	Coef. Sorção (S)	Coef. Permeab. (k)		
B=baixo (a)		< 4		< 0,5		< (-2)	< (-6)		
M=médio (a)		4 a 12		0,5 a 3		(-2) a (-1)	(-6) a (-3)		
E=elevado (a)		12 a 30		> 3		> (-1)	> (-3)		
EE=muito elevado (a)		> 30							

4.2.3. COMPACTAÇÃO MINI-PROCTOR

Este ensaio foi desenvolvido na *Iowa State University* e adaptado por NOGAMI (1972), a fim de correlacionar seus resultados com os obtidos com o CBR, realizado de acordo com o método adotado no Brasil. As causas que levaram ao desenvolvimento dessa adaptação foram as limitações dos procedimentos tradicionais de previsão do CBR, sobretudo com base nas propriedades dos índices dos solos (por exemplo, a granulometria).

O conjunto de ensaios que utiliza este tipo de compactação é designado de Ensaio Mini-CBR e Associados. Geralmente, após a compactação dos corpos de provas, avalia-se uma série de propriedades. As que foram determinadas nesse estudo são:

- (a) capacidade de suporte (Mini-CBR), que permite avaliar a capacidade de suporte do solo em resistir as solicitações;
- (b) expansão, que estima o aumento de volume, em porcentagem, quando uma massa de solo estiver em contato com a água;
- (c) contração, que avalia as condições de trincamento do solo por secagem.

Ressalta-se que a Classificação MCT é atualmente o procedimento que permite caracterizar melhor os solos tropicais para as nossas condições ambientais, onde a aparelhagem necessária é predominante de baixo custo e de construção relativamente fácil, mas ainda não padronizada internacionalmente.

Cabe ressaltar que a classificação MCT apresenta algumas restrições quanto ao seu uso, devido aos processos de ensaios que são relativamente complexos e de difícil assimilação por parte dos técnicos que os executam, além de solicitarem um certo tempo de execução e por fim a determinação dos resultados, construção das curvas e interpretação dos resultados.

4.3. A UTILIZAÇÃO DO ENSAIO DE ADSORÇÃO DE AZUL DE METILENO PELO MÉTODO DA MANCHA NA CARACTERIZAÇÃO DE SOLOS

Surgiram estudos para classificar solos tropicais por um processo mais simples e rápido quando comparado com a Classificação MCT. O ensaio de adsorção de azul de metileno vem se mostrando eficiente e simples para a classificação de solos tropicais. Esse ensaio é utilizado na França pelo *Laboratoire Central des Ponts et Chaussées* (LAN, 1977), para a classificação e a caracterização de solos. No Brasil, estudos realizados como o de FABRI (1994) comprovam que o ensaio de adsorção de azul de metileno surge como uma alternativa inovadora, rápida e econômica para o processo de caracterização dos solos.

Um dos trabalhos pioneiros na utilização do ensaio de adsorção de azul de metileno foi feito por LAN (1977), do LCPC (*Laboratoires des Ponts et Chaussées*). Este autor estudou o ensaio de adsorção de azul de metileno pelo método da mancha para caracterização de solos e correlacionou os resultados com o índice de plasticidade e com o equivalente areia. Com este trabalho, as pesquisas no LCPC evoluíram e em 1979 foi publicado o anteprojeto de padronização do ensaio de adsorção de azul de metileno pelo método da mancha.

O valor de azul (V_b) foi definido como a quantidade de corante adsorvido por 100 g de solo. Assim, pode-se avaliar o grau de contaminação de areias e de materiais granulares pelas argilas, bem como a argilosidade de solos dentro do domínio da geotecnia, em função do consumo de corante.

Neste anteprojeto, foi definido o coeficiente de atividade das frações granulométricas dos solos como sendo a razão entre o “valor de azul” (V_b) do solo multiplicado por 100 e a porcentagem que o solo possui na peneira em análise (por exemplo, para $\% < 2\mu\text{m}$). Dessa forma, o coeficiente de atividade da fração granulométrica menor que 0,002 mm é calculado segundo a expressão:

$$CA_2 = \frac{Vb \times 100}{\% < 2\mu\text{m}} \quad (4.2)$$

onde:

CA₂: coeficiente de atividade do solo para a fração menor que 0,002 mm;

Vb: valor de azul do solo (g de azul/100 g de solo);

%<2μm: porcentagem do solo menor que 0,002 mm.

LAN (1980) apresentou um estudo que relacionava a variação do consumo de azul de metileno com misturas de argila, concluindo que a presença de quantidade excessiva de elementos inertes presentes em um solo não influencia a adsorção de azul de metileno.

LAN (1981) propôs uma alteração na classificação de solos da RTR (*Recommandation pour Terrassements Routiers*), com a introdução do ensaio de azul de metileno pelo método da mancha. Assim, utilizou os valores de azul para identificar as classes de solos, concluindo que ensaio de azul de metileno pelo método da mancha é um ensaio simples, podendo ser um critério seguro para identificar e classificar os solos.

LAUTRIN (1987) estudou 99 amostras de solos com proporções variadas de diferentes argilo-minerais e definiu um método para identificação do tipo de argilo-mineral a partir do ensaio de adsorção de azul de metileno pelo método da mancha.

Foi definido, por LAUTRIN (1987), um índice de nocividade (N), como sendo a razão entre a massa de azul de metileno necessária para recobrir com uma camada monomolecular as partículas contidas em 100 g de um solo e a porcentagem da fração do solo menor que # 0,002 mm, conforme mostra a expressão apresentada a seguir:

$$N = \frac{100 \times Vb}{C_2} \quad (4.3)$$

onde:

N: índice de nocividade;

Vb: valor de azul adsorvido (g/100 g de solo);

C₂: porcentagem do solo que passa na # 0,002 mm.

LAUTRIN (1987) procurou associar o valor da adsorção de azul de metileno (Vb) com a mineralogia das argilas. Desta forma, estabeleceu a influência da mineralogia das argilas sobre a adsorção do azul de metileno.

A Tabela 4.3 apresenta as composições das amostras utilizadas por LAUTRIN (1987) e a Figura 4.2 apresenta a influência da composição no Vb. Nesta figura verifica-se que houve relação direta entre o aumento da porcentagem de argila e o aumento da adsorção de azul de metileno. Nota-se ainda que, com a variação da proporção de diferentes tipos de argila dentro da fração argilosa, ocorreram mudanças na quantidade adsorvida.

Tabela 4.3 - Composições das frações argila utilizadas por LAUTRIN (1987).

Amostra	Caulinita (%)	Ilita (%)	Montmorilonita (%)
A	100	0	0
B	95	5	0
C	95	0	5
D	0	100	0
E	80	0	20
F	10	45	45
G	0	98	2
H	15	0	85
I	10	0	90

Segundo LAUTRIN (1987), para argilo-minerais puros, encontraram-se os seguintes valores do índice de nocividade: 1 a 2 para caulinitas, 4 e 5 para as ilitas e 18 a 20 para as montmorilonitas. Sua conclusão foi que o ensaio de adsorção de azul de metileno pelo método da mancha é um excelente ensaio para a caracterização de solos, fornecendo um meio de qualificar sua fração fina.




Figura 4.2 - Variação da adsorção de azul de metileno em função da composição das argilas, segundo LAUTRIN (1987).

4.3.1. ESTUDOS REALIZADOS NO BRASIL

CASANOVA (1986), segundo FABBRI (1994), analisou trinta e cinco amostras de solos lateríticos brasileiros com o objetivo de caracterização e controle de qualidade aplicados à pavimentação. Foram estudados solos lateríticos com razão sílica-alumina (K_i) entre 0,37 a 1,97 e razão sílica-sesquióxidos (K_r) variando de 0,27 a 1,93. Nesses solos foram determinadas a superfície específica (SE) e a capacidade de troca catiônica (CTC) pelos métodos tradicionais e os resultados foram comparados com os obtidos a partir de ensaios de azul de metileno pelo método da mancha. Os resultados indicaram uma boa correlação entre a CTC obtida pelos métodos tradicionais e a obtida pelo ensaio de adsorção de azul de metileno pelo método da

mancha, sendo que, para todos os solos analisados, a CTC pelo ensaio de azul de metileno pelo método da mancha foi sempre menor que a obtida pelo método tradicional.

CASANOVA (1986) citou ainda que não houve uma completa adsorção do azul de metileno pela matéria humificada; que os materiais paracristalinos e amorfos adsorviam pequena quantidade de azul de metileno e que não houve adsorção de azul de metileno pelos óxidos e hidróxidos livres de ferro e alumínio (goetita, gíbssita, etc). Tais fatores contribuíram para a aplicação do ensaio de adsorção de azul de metileno pelo método da mancha na caracterização de solos, pois a matéria orgânica, os oxí-hidróxidos livres e o material amorfo praticamente não adsorviam azul de metileno. O método mede essencialmente a capacidade de troca catiônica dos argilo-minerais presentes nas amostras. Este autor concluiu que o ensaio de adsorção de azul de metileno pelo método da mancha deve ser adotado como meio para a caracterização de solos lateríticos, uma vez que propiciou uma maneira rápida, simples e eficaz de determinar as propriedades químicas e físico-químicas de superfície dos solos lateríticos.

FABBRI & SÓRIA (1991) utilizaram o ensaio de adsorção de azul de metileno pelo método da mancha para fins de classificação de solos, tendo sido ensaiadas quarenta e cinco amostras de solos provenientes de diversos locais do estado de São Paulo, com a finalidade de verificar a variação do consumo de corante em função da classe dos solos obtida da classificação MCT (FABBRI, 1994).

Para a avaliação da “atividade” dos argilo-minerais presentes nos solos, estes autores definiram um coeficiente de atividade (CA), semelhante ao índice de nocividade de LAUTRIN (1987), conforme a expressão apresentada a seguir:

$$CA = 100 \frac{VT}{P_F} \quad (4.4)$$

onde:

CA: coeficiente de atividade (10^{-3} g/g%);

P_F : porcentagem, em peso, que o solo contém da fração que se quer avaliar a atividade (%);

VT: volume total de solução de azul de metileno consumido por 1 g de amostra de solo integral seco (com concentração de 1,0 g de sal anidro por litro de solução) (ml).

Como o ensaio foi executado com 1 g da fração do solo que passa na # 0,074 mm, para o cálculo do volume total (VT), tornou-se necessário levar em consideração a porcentagem que o solo tinha nesta peneira e o teor de umidade que possuía no momento do ensaio. Este cálculo foi realizado segundo a seguinte expressão:

$$VT = V \times \frac{P_{200}}{100} \times \left(1 + \frac{w}{100}\right) \quad (4.5)$$

onde:

VT: volume total de azul de metileno consumido por 1 g de amostra de solo integral (ml);

V: volume de azul de metileno adicionado à suspensão durante o ensaio (ml);

P_{200} : porcentagem do solo que passa na #0,074 mm;

w: teor de umidade do solo ensaiado (%).

Esses autores verificaram que existe uma boa concordância entre o índice e' da classificação MCT (índice que caracteriza o "caráter" laterítico do solo) e o coeficiente de atividade proposto (CA), tanto para ensaios com variação de pH, como para os diferentes diâmetros que definem a fração ativa.

PEJON (1992) utilizou o ensaio de adsorção de azul de metileno pelo método da mancha para caracterizar solos para fins de mapeamento geotécnico. Foi realizado o ensaio com a fração granulométrica passada na #2,00 mm e com uma concentração da solução de azul de metileno de 1,5 g/l, devido à baixa adsorção do corante pelos solos tropicais. Segundo FABBRI (1994), com os resultados dos ensaios deste estudo foram calculados a capacidade de troca catiônica (CTC), a superfície específica (SE), o valor de azul do solo (V_b) e o valor de azul da fração argila (A_{cb}). A CTC obtida

do ensaio de azul de metileno pelo método da mancha foi comparada, para cinquenta e três amostras, com a obtida pelo método utilizado no Instituto Agrônomo de Campinas, sendo conseguida uma boa correlação entre os dois resultados.

PEJON (1992) avaliou ainda o comportamento laterítico ou não dos solos utilizando o Vb (quantidade de azul de metileno, em peso, consumida por 100 g de solo) juntamente com os resultados da classificação MCT. Concluiu que, para as cento e oito amostras analisadas, o Vb distinguiu, com uma probabilidade de 85% de acerto, os solos de comportamento laterítico dos de comportamento não laterítico. Este autor utilizou ainda o valor de azul da fração argila do solo - Acb (quantidade de azul de metileno, em peso, consumida por 100 g da fração argilosa do solo) para avaliar a atividade do argilo-mineral presente.

FABBRI (1994) apresentou uma proposta para caracterização da fração fina de solos tropicais, baseada na superfície específica dos argilo-minerais nela presentes, medida pelo ensaio de adsorção de azul de metileno pelo método da mancha. A partir da superfície, determinada pela adsorção do corante azul de metileno, foram estabelecidos graus de atividade para os solos analisados. Esta atividade foi então comparada com a previsão de comportamento dos solos, obtida da classificação MCT. Este autor concluiu que a utilização da adsorção de azul de metileno é promissora para a caracterização da fração fina de solos tropicais, permitindo estabelecer, com razoável segurança, a atividade dos argilo-minerais presentes e ainda que existe uma boa concordância entre os resultados da adsorção de azul de metileno e os fornecidos pela classificação MCT para solos tropicais.

Logo FABBRI (1994) concluiu que o ensaio de adsorção de azul de metileno é uma forma de identificar o comportamento laterítico dos solos e, juntamente com a execução de ensaios de granulometria com sedimentação, admite a determinação da quantidade da fração granulométrica correspondente a argila ($<0,005$ mm) dos solos, com a finalidade de calcular a atividade da fração fina. O ensaio consiste basicamente na determinação do chamado coeficiente de atividade (CA). Esse coeficiente, definido por FABBRI & SÓRIA (1991), é descrito pela expressão 4.6.

$$CA = 100 \times \frac{Va}{Pf} \quad (4.6)$$

onde:

Va: valor de azul (quantidade de azul de metileno consumida em g por 1 g de amostra de solo integral) (ml);

Pf: porcentagem em peso que o solo contém da fração cujo grau de atividade se quer avaliar (%).

FABBRI (1994) apresentou um ábaco para a identificação dos argilo-minerais presentes na fração fina do solo analisado. Nesse ábaco, conforme pode ser observado pela Figura 4.3, o coeficiente de atividade (CA) é a relação entre o valor da ordenada de um ponto e o valor da abscissa correspondente ou ainda, no caso da reta arbitrada, seu coeficiente angular, expresso em porcentagem de partículas com dimensões inferiores a 0,005 mm.

Segundo esse autor pode-se apresentar três graus de atividade para os grupos de argilo-minerais, conforme seus coeficientes de atividade (CA):

- i. “CA > 80 (muito ativos) incluem argilo-minerais dos grupos das montmorilonitas, vermiculitas, etc;
- ii. 11 < CA < 80 (ativos) incluem argilo-minerais dos grupos das caulinitas e/ou ilitas, ou ainda combinações destes com os de grupos mais ativos e de grupos menos ativos, desde que em proporções compatíveis com o CA encontrado;
- iii. CA < 11 (pouco ativos) abrangem desde materiais inertes até argilo-minerais laterizados ou ainda combinações entre estes e os de outros grupos mais ativos, desde que em proporções compatíveis também com o valor de CA (neste caso, pequenas proporções).”

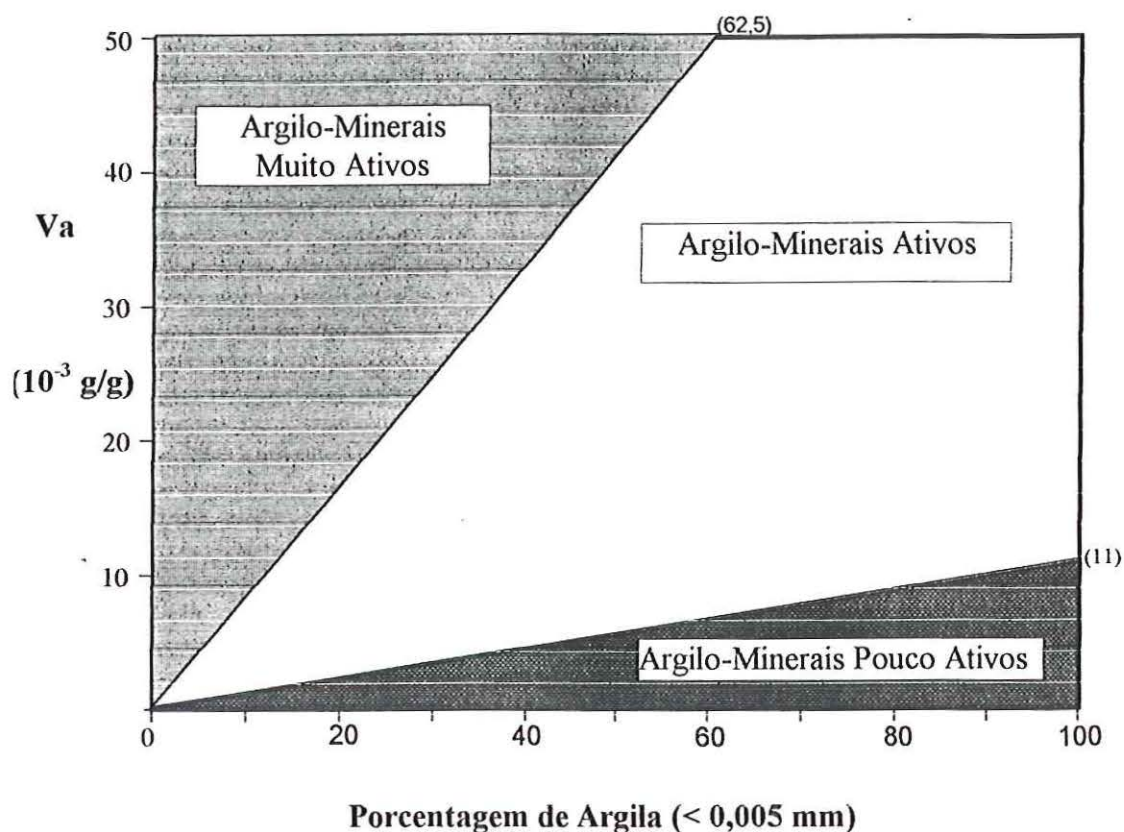


Figura 4.3 - Ábaco para caracterização do grau de atividade da fração argila dos solos, segundo FABRI (1994).

4.4. A UTILIZAÇÃO DAS CORES NA CLASSIFICAÇÃO DE SOLOS

A cor é, entre todas as características do solo, a de mais fácil visualização, seja na identificação e delimitação de horizontes de um perfil, seja na distinção entre solos diversos, por representar diferenças constitucionais entre eles. Muitos nomes populares de solos são dados em função das respectivas colorações, como por exemplo “terra roxa”, “terra preta”. Os solos escuros por exemplo, a princípio, indicam altos teores de restos orgânicos decompostos; por outro lado a cor vermelha, está relacionada com solos bem drenados e altos teores de óxidos de ferro; tons cinza-azulados indicam solos que têm excesso de água no perfil, como os situados nas baixadas úmidas próximas aos rios e riachos. Logo, o conteúdo de matéria orgânica, as condições de drenagem e aeração de solo, o material original e a intensidade dos processos de alteração podem influenciar na determinação da cor do solo.

Apesar de ter pouca implicação no comportamento do solo, a cor está relacionada com suas características mineralógicas, físicas e químicas, possibilitando induzir sobre a natureza e/ou estado de constituintes a que o solo está ou esteve sujeito. Pelo conhecimento da cor pode-se prever algumas de suas características e do comportamento do material.

4.4.1. A ORIGEM DA COR DO SOLO

Os agentes de coloração mais comuns do solo são os óxidos de ferro e a matéria orgânica. Os compostos de manganês também podem ser importantes em alguns solos. Nos solos tropicais ocorrem em abundância os óxidos ou hidróxidos de ferro, alumínio e o manganês que cobrem as partículas minerais (areia, silte e argila).

Os compostos de ferro possuem, normalmente, tonalidades que variam do vermelho ao marrom, sob condições de boa drenagem. Como a quantidade de óxidos de ferro pode variar, assim também a intensidade da cor vermelha pode indicar a quantidade de ferro herdada do material geológico que deu origem ao solo. Os solos com baixos conteúdos de ferro geralmente não possuem as cores vermelhas comuns aos solos de basalto. Já os solos originados de rochas com baixo conteúdo de ferro tendem a possuir colorações pálidas. As cores do solo refletem diretamente as cores do material geológico que o originou (LEMOS & SANTOS, 1996).

Sob condições de má drenagem, em solos saturados de água, os compostos de ferro e manganês estão reduzidos (ou seja, ganham elétrons) dando cores que variam do cinza ao azul. Sob condições de flutuação do lençol freático, o ferro é reduzido durante períodos úmidos e oxidado (perda de elétrons) durante períodos mais secos subsequentes. Assim manchas de cores vermelhas, amarelas ou marrons mosqueiam a matriz azul-cinza de ferro reduzido, ou manchas amarelas, marrons e cinzas mosqueando uma matriz vermelha do ferro oxidado. Os óxidos de ferro são vermelhos, mesmo com baixa hidratação. Quando são medianamente hidratados são de cor laranja e quando altamente hidratados são amarelos.

Uma camada muito clara sob horizontes orgânicos de superfície geralmente indica intensa lixiviação do solo. É sintomático a perda de agentes de coloração do

horizonte (ferro, manganês, matéria orgânica), deixando permanecer a matriz de silicosa esbranquiçada. O manganês tende a dar cores negras ao solo.

A matéria orgânica também dá colorações escuras (preto e marrom) ao solo e isto depende da natureza química, da quantidade e da forma da matéria orgânica. O horizonte superficial de um solo sob pastagem tende a ser preto, mas debaixo de uma floresta tende a ser mais marrom. Os horizontes superficiais tendem a ser mais escuros que os horizontes mais profundos. A presença de conteúdos elevados de cálcio e magnésio pode levar cores esbranquiçadas ao solo. Entretanto nem todas as cores escuras são, necessariamente, devido à matéria orgânica (LEMOS & SANTOS, 1996).

4.4.2. SISTEMA DE COR DE MUNSELL

Em 1912, o pintor norte-americano Albert Henry Munsell (1858-1918) propôs um sistema que é considerado o melhor sistema baseado em princípios perceptuais, amplamente exposto no Atlas do Sistema de Cores *Munsell (Atlas of the Munsell Color System, 1914)*, e em 1942 foi adotado oficialmente pelo governo dos Estados Unidos da América, ou seja, pela Associação Norte-Americana de Normas. Depois da morte de Munsell foram rigorosamente determinados os comprimentos de onda, brilho e saturação das amostras do *Munsell Book of Color* (PEDROSA, 1982).

O sistema de ordenação de cores de *Munsell* é denominado, também, de sistema HSV (*Hue*: matiz; *saturated*: saturação e *Value*: valor). O matiz é aquilo que normalmente e impropriamente chamamos de "cor". Para Munsell, matiz é a propriedade pela qual descrevemos as cores, por exemplo: vermelho, amarelo etc., distinguindo assim uma família de cor da outra. A intensidade, ou valor, é uma propriedade acromática, ou seja, existe com a ausência de qualquer matiz. Pode também ser chamada de brilho e é o fator mais importante na seleção de cor. Distingue cores claras das escuras. A saturação, ou croma, está intimamente ligada ao matiz, e é através desta dimensão que se explica o fenômeno de uma cor ser mais amarela ou menos amarela, mais vermelha ou menos vermelha. Pode-se, portanto, ter um mesmo matiz com saturações diferentes.

Essas três variáveis, segundo Munsell, podem ser representadas por dois cones sobrepostos pela base (Figura 4.4) colocando-se a claridade (valor) variando no sentido do eixo, é a quantidade relativa de claro ou escuro em uma escala do preto ao branco (de baixo para cima); o matiz no círculo central, compondo o comprimento de onda espectral da cor que produz a percepção de ser azul, laranja, marrom, etc, e a saturação (croma) no raio deste círculo.




Figura 4.4 - Triângulo de cores de acordo com o sistema *Munsell* de cores.
(PEDROSA, 1982)

4.4.3. ESCALA *MUNSELL* DE CORES PARA SOLOS

Para fins de uniformização na identificação das cores dos solos, usam-se escalas de padrões comparativos, sendo a mais empregada a Escala *Munsell* de Cores para Solos (*Munsell Soil Color Charts*, 1975), onde o procedimento de designação da cor de um solo, com o auxílio da escala, é realizado visualmente a olho nu com as amostras num ambiente com iluminação natural. Nessa tabela (escala) existem várias

cartelas de cores e, em cada uma, constam as três variáveis o matiz (*hue*), o valor (*value*) e o croma (*chroma*).

O matiz refere-se à combinação de pigmentos vermelho (*red*) e amarelo (*yellow*). Na escala *Munsell* o matiz é representado por notação formada por um número e uma ou duas letras.

Os números simbolizam a gradação cromática, escalonada segundo valores de 0 a 10. As letras são abreviaturas, denotando denominação em inglês das gamas de cores do espectro solar aplicáveis aos solos: R para vermelho, YR para alaranjado, Y para amarelo. Em cada gama de cor, o matiz é mais pigmentado de amarelo e menos de vermelho, progressivamente, com aumento da numeração anteposta às letras da notação. No sistema *Munsell* esses matizes são representados pelas notações 5R (vermelho pleno); 7,5R; 10R (= zero YR); 2,5 YR; 5YR (alaranjado pleno); 7,5YR; 10 YR (= zero Y); 2,5Y; 5Y (amarelo pleno). Ocasionalmente, sob condições de hidromorfia, ocorrem matizes GY (oliva), G (verde), BG (ciano) e B (azul). Se, por exemplo, a anotação do matiz for 7,5YR, significa que há combinação de 62,5% de amarelo (Y) e 37,5% de vermelho (R), conforme apresentado na Figura 4.5.

O valor traduz a tonalidade mais clara ou mais escura da cor. É resultante das proporções variáveis de preto e de branco combinados com um matiz qualquer. No sistema *Munsell*, o valor zero corresponde ao preto absoluto e o 10 ao branco absoluto (ambos inexistentes em solos) e esses números estão dispostos no sentido vertical na tabela de cores. Por consequência, nessa escala são apresentadas apenas as variações de tonalidades expressas pelas notações de 2 a 8: 2 corresponde à proporção de dois décimos de branco com 8 décimos de preto; 8 ao inverso. A associação de 5 partes de branco com 5 partes de preto é expressa pelo valor 5, que corresponde ao cinzento pleno. Os valores 6, 7 e 8 correspondem a tonalidades de cinzento, progressivamente mais claras, enquanto 4, 3 e 2 correspondem a tonalidades progressivamente mais escuras de cinzento.

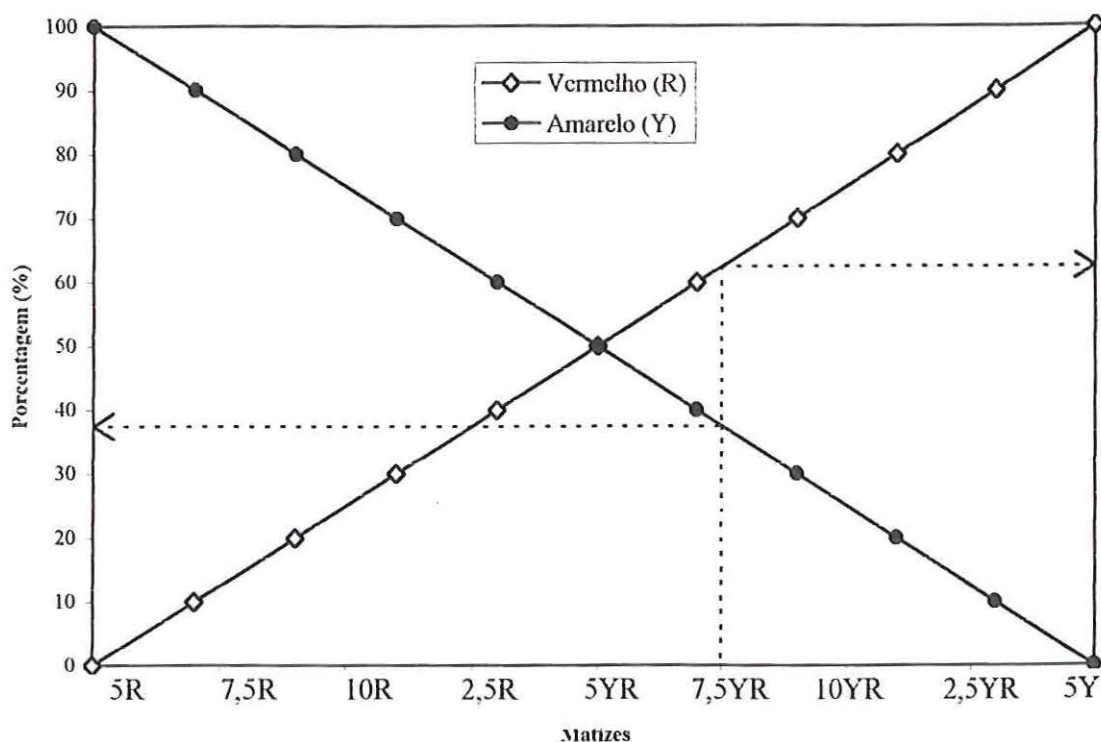


Figura 4.5 – Ilustração da contribuição das cores vermelha e amarela na formação do matiz. (PRADO, 1993)

O croma, que representa a pureza da cor, traduz a saturação ou a intensidade do colorido. Sua codificação indica a proporção de matiz que está combinado com algumas das tonalidades de cinzento. A resultante cromática exposta pelo material do solos decorre da combinação de uma das tonalidades de cinzento (valor) com dada saturação de um matiz, totalizando a mistura vinte partes. Croma zero representa, portanto, vinte partes das tonalidades de cinzento e nenhuma parte de matiz, e croma sete representa treze partes de cinzento e sete de um dado matiz. Os números do croma estão dispostos na tabela de cor no sentido horizontal

Na escala *Munsell* completa são apresentadas todas as combinações até o croma vinte, que traduz a cor espectral pura, sem mistura com qualquer tonalidade de cinzento. Porém, na escala de cores *Munsell* construída para uso em solo, o croma máximo é oito, pois intensidades maiores de colorido não são pertinentes. Para cores acromáticas absolutas – branco, preto e cinzento puros – o croma é zero, expressando

ausência de matiz. Nesse caso, a notação N (neutro) substitui a designação de matiz (OLIVEIRA *et al.*, 1992).

A escala apresenta também para cada codificação o respectivo nome da cor. A notação 2,5YR $\frac{3}{4}$, por exemplo, significa que o material componente tem coloração correspondente no sistema *Munsell* ao matiz 2,5YR, valor 3 e croma 4, e representa a cor denominada bruno-avermelhado-escuro. A Figura 4.6 apresenta a distribuição do matiz, valor e croma do sistema *Munsell*.




Figura 4.6: Distribuição do matiz, valor e croma do sistema *Munsell* (Ku School of Architecture, 2000).

Segundo ESPINDOLA & MILLER (1979), a cor permite facilmente separar os Latossolos em Latossolo Vermelho Escuro e Latossolo Vermelho Amarelo. O Latossolo Roxo apresenta, via de regra, coloração vermelha intensa, normalmente tida como arroxeada, em geral de matiz 10 R ou 2,5 YR.

Pelo método visual de identificação das cores pode-se reconhecer os solos lateríticos que constituem a parte mais superficial do subsolo, das áreas bem drenadas (acima do lençol freático, indicado pela ausência de cursos d'água permanentes) que se destacam do perfil do mesmo, pela sua uniformidade e sua coloração características: vermelha, alaranjada ou amarela, raramente com outras cores.

CAPÍTULO 5: MATERIAIS E MÉTODOS

Neste capítulo apresentam-se os procedimentos adotados para o desenvolvimento deste trabalho. O processo de coleta das amostras de solos e os ensaios realizados para caracterização de cada uma dessas amostras, para gerar o conjunto de dados para implementar o processo de aprendizado das Redes Neurais Artificiais. A seguir é explicada a forma de tratamento da base de dados de entrada utilizada no treinamento das RNAs.

5.1. COLETA DOS MATERIAIS

As amostras de solos utilizadas nesse estudo são provenientes da área que compreende o município de São Carlos, localizado na região centro-oeste do Estado de São Paulo, entre as coordenadas 21°36'-22°10'S e 47°43'-48°06'WG, tendo uma área total de 1132 km² (55,2 km² de área urbana), segundo a Prefeitura Municipal de São Carlos. O município de São Carlos faz limite com outros 11 municípios: Américo Brasiliense, Analândia, Araraquara, Brotas, Descalvado, Ibaté, Itirapina, Luis Antonio, Ribeirão Bonito, Rincão e Santa Lúcia.

Segundo PRADO *et al.* (1981), as principais classes pedológicas de solos encontradas no município de São Carlos, são: Latossolo Vermelho-Amarelo (LV), Latossolo Roxo (LR), Areia Quartzosa Profunda (AQ), Latossolo Vermelho-Escuro (LE), Litólico (Li), Podzólico Vermelho-Amarelo (PV), Terra Roxa Estruturada (TE). Com o auxílio das Cartas Pedológicas do IAC (Instituto Agrônomo de Campinas), escala 1:100.000, onde o município de São Carlos encontra-se inserido em três quadriculas (São Carlos, Descalvado e Brotas), determinou-se as áreas de ocorrência de cada classe pedológica no município, conforme apresentadas na Tabela 5.1.

Tabela 5.1: Áreas de ocorrência de cada classe pedológica no município de São Carlos (SP).

Classe Pedológica	Área de ocorrência no município	
	(km ²)	(%)
LV	390,20	34,47
LR	232,97	20,58
AQ	196,63	17,37
LE	153,61	13,57
Li	55,58	4,91
PV	44,37	3,92
TE	23,43	2,07

Observa-se, conforme Tabela 5.1, que a área de ocorrência de cada uma das sete classes pedológicas variam no município. Desta forma, há classes pedológicas que apresentam uma área de ocorrência superior às outras. Considerando essa heterogeneidade espacial entre as classes, selecionou-se o número de amostras por classe pedológica em função de sua proporcionalidade dentro do município. Assim, as amostras foram coletadas, com o intuito de abranger todo o município em relação a representação das classes, em um total de cento e uma amostras de solos, distribuídas conforme a Tabela 5.2.

Tabela 5.2: Número de amostras coletadas em função das áreas de ocorrência de cada classe pedológica no município de São Carlos (SP).

Classe Pedológica	Número de amostras
LV	35
LR	22
AQ	17
LE	16
Li	5
PV	4
TE	2

Para as coletas de material, demarcou-se os pontos de coleta nas cartas pedológicas do IAC (escala 1:100.000), confrontando os locais onde a ocorrência da classe pedológicas encontrava-se próximas às margens de rodovias pavimentadas e não pavimentadas, procurando abranger todo o município de São Carlos com um fácil acesso pelas vias.

A Figura 5.1 apresenta as localizações esquemáticas, no mapa do município de São Carlos (SP), dos pontos de coleta; maiores detalhes das localizações podem ser encontrados no Anexo A.



Figura 5.1: Mapa do município de São Carlos (SP), mostrando a localização aproximada dos pontos de coleta das amostras de solos estudadas.

5.2. MÉTODOS DE ENSAIOS

As cento e uma amostras de solos foram submetidas ao programa de ensaio descrito nos itens que se seguem. Todos os ensaios foram executados no Laboratório de Estradas do Departamento de Transportes da Escola de Engenharia de São Carlos da Universidade de São Paulo.

5.2.1. MASSA ESPECÍFICA DOS SÓLIDOS

A determinação da massa específica dos sólidos, necessária aos cálculos do ensaio de granulometria por sedimentação, foi realizada de acordo com o método de ensaio “Densidade Real dos Solos” – ME 93-94, do Departamento Nacional de Estradas, DNER.

5.2.2. GRANULOMETRIA POR SEDIMENTAÇÃO

A análise granulométrica por sedimentação foi executada utilizando-se o método de ensaio “Análise Granulométrica de Solos – ME 51-64, do Departamento Nacional de Estradas de Rodagem, DNER. O defloculante usado para a dispersão das amostras foi o hetametafosfato de sódio, na concentração indicada.

5.2.3. LIMITE DE LIQUIDEZ

O valor do limite de liquidez foi determinado conforme o método de ensaio ME 44-71, do Departamento Nacional de Estradas, DNER.

5.2.4. LIMITE DE PLASTICIDADE

O valor do limite de plasticidade foi determinado conforme o método de ensaio ME 82-63, do Departamento Nacional de Estradas, DNER.

5.2.5. MINI-CBR, EXPANSÃO E CONTRAÇÃO

Os ensaios de Mini-CBR, expansão e contração foram realizados nas energias de compactação normal e intermediária. Os ensaios foram executados de acordo com os procedimentos dos métodos de ensaio DER M 192-88 (ensaio de Mini-CBR), DER M 192-88 (ensaio de expansão) e DER M 193-88 (ensaio de contração).

5.2.6. MINI-MCV E PERDA DE MASSA POR IMERSÃO

Os ensaios de Mini-MCV e perda de massa por imersão foram executados conforme os procedimentos dos métodos de ensaio DER M 191-88 (ensaio de mini-MCV) e DER M 196-88 (perda de massa por imersão), ambos do Departamento de Estradas de Rodagem de Estado de São Paulo.

5.2.7. ADSORÇÃO DE AZUL DE METILENO PELO MÉTODO DA MANCHA

O ensaio de adsorção de azul de metileno pelo método da mancha foi executado objetivando determinar os valores de azul e os coeficientes de atividade dos solos ensaiados. Trabalhou-se com o pH normal da suspensão solo+água, através da adição do solo à água destilada. A porção de solo ensaiada foi a passada na peneira de abertura nominal igual a 0,074 mm.

Os ensaios de adsorção de azul de metileno pelo método da mancha foram executados segundo o método desenvolvido por FABBRI (1994), onde o valor de azul de metileno de um solo (V_a) é a quantidade de azul de metileno consumida em g por 1 g de solo. O valor de azul (V_a) é dado pela expressão a seguir:

$$V_a = V \cdot \frac{P_{200}}{100} \left(1 + \frac{w}{100} \right) \quad (4.6)$$

onde:

V_a : valor de azul, corresponde a quantidade de azul de metileno consumida por 1 g de amostra de solo integral expressa em ml de solução padrão por grama de solo, ou por 10^{-3} g de azul de metileno por g de solo (10^{-3} g/g de solo);

V: volume de solução padrão de azul de metileno adicionado à suspensão (ml);

P_{200} : porcentagem do solo que passa na peneira de número 200 (%);

w: teor de umidade da amostra de solo ensaiada (%).

5.2.7.1. APARELHAGEM E MATERIAIS

Para a execução, de acordo com FABBRI (1994), do ensaio de adsorção de azul de metileno pelo método da mancha, são necessários os seguintes aparelhos e materiais:

- peneira de malha quadrada de #0,074 mm;
- agitador magnético para soluções aquosas com possibilidade de regulação do número de rotações;
- cronômetro, com resolução de segundos;
- baguete cilíndrica de vidro, com aproximadamente 8 mm de diâmetro e 250 mm de comprimento;
- bureta de vidro de 25 ml de capacidade e graduada de 0,1 em 0,1 ml;
- suporte para bureta;
- béquer de vidro com capacidade para 250 ml;
- provetas de vidro com capacidade 100 e 1000 ml;
- papel de filtro circular, com diâmetro entre 120 e 150 mm, para micro-cristais, com teor de cinzas inferior a 0,01%, do tipo Reagen R-42, Whatman 42 ou similar;
- solução aquosa padrão de azul de metileno, com concentração de 1,0 g de sal anidro por litro de solução;
- água destilada.

5.2.7.2. EXECUÇÃO DO ENSAIO

A execução do ensaio de adsorção de azul de metileno pelo método da mancha segue os seguintes procedimentos, descritos em FABBRI (1994):

- a) passar uma porção do solo (seca ao ar) na peneira 200; retirar o teor de umidade da amostra de solo ensaiada, pesar 1,00 g e colocá-la no bequer de 250 ml;
- b) adicionar 100 ml de água destilada ao bequer;
- c) colocar o bequer contendo a suspensão solo + água destilada no agitador magnético;
- d) através da bureta graduada, colocar no bequer 1,0 ml de solução padrão de azul de metileno e acionar o cronômetro, aguardando 1 minuto;

- e) introduzir a baguete de vidro na suspensão, sem desligar o agitador magnético, capturar uma gota de suspensão e pingá-la em uma folha de papel de filtro;
- f) observar a difusão da gota no papel de filtro. Deverá aparecer uma mancha circular, composta de um núcleo escuro que contém as partículas sólidas da suspensão (solo), circundada por uma borda de cor mais clara, correspondente à fase líquida da suspensão filtrada pelo papel de filtro;
- se houver, após a difusão da água, o aparecimento de uma aura azulada ou esverdeada em torno da borda que circunda o núcleo escuro da mancha, esperar por mais 3 minutos e repetir os itens e) e f). Se a aura persistir, após passados os 3 minutos, significa que há excesso de corante na solução e o ponto de viragem foi atingido;
 - se não houver o aparecimento da aura, ou esta desaparecer após os 3 minutos de espera, repetir a operação a partir do item d), até que o teste da mancha persista por 3 minutos ou mais, conforme descrito acima;
- g) anotar a quantidade de solução padrão de azul de metileno (V) correspondente ao ponto de viragem do teste de mancha, expressa em ml.

Com o valor do volume do azul de metileno consumido pela fração fina do solo durante a realização do ensaio, obtém-se da expressão (4.6), o valor de azul (V_a).

5.2.8. IDENTIFICAÇÃO VISUAL DAS CORES

A identificação visual das cores usando-se escalas de padrões comparativos, como a Escala *Munsell* de Cores para solos (*Munsell Soil Color Charts*, 1975) foi executada objetivando designar a cor de cada amostra de solo.

5.3. REDES NEURAS ARTIFICIAIS IMPLEMENTADAS

As Redes Neurais Artificiais utilizadas neste estudo são do tipo Multicamadas Perceptron (*Perceptron MultiLayer* - MLP). Esse modelo é apropriado aos problemas de previsão e classificação e o seu treinamento será feito com o algoritmo *backpropagation* (RUMELHART *et al.*, 1986), que é um dos mais utilizados para o treinamento de redes com mais de uma camada. Esse tipo de rede tem sido utilizado

com eficiência no campo da engenharia, para simulação de processos químicos e biológicos (MORRIS, 1994; BHAT, 1990).

O processo de aprendizagem da rede inclui três fases: o treinamento, o teste e a validação. Segundo PRECHELT (1994), os conjuntos de dados são divididos, de forma aleatória, em três subconjuntos distintos, destinados para cada uma das três fases: treinamento (50% dos dados), teste (25% dos dados) e validação (25% dos dados). Os conjuntos de dados para o treinamento, o teste e a validação não devem apresentar dados em comum entre eles e os dados utilizados para qualquer uma das fases não podem ser repetidos em outra fase. Este procedimento deve ser repetido três vezes para que não haja a possibilidade da rede memorizar os resultados e sim generalizá-los.

O conjunto de dados em estudo, conforme Tabela 5.2, compreende sete classes pedológicas que variam entre si no número amostras, em função das áreas de ocorrência de cada classe pedológica no município de São Carlos. Neste caso, a amostragem não é homogênea, existindo classes com número de amostras significativamente superior às demais. Cabe ressaltar que esta heterogeneidade é atribuída às características da região estudada e, se fosse realizada a divisão aleatória do conjunto total de dados sem considerar as subdivisões de classes com tamanhos diferentes, o processo de aprendizagem das redes poderia ser comprometido. Para evitar isso, adotou-se uma amostragem estratificada proporcional.

Na amostragem estratificada proporcional, segundo COSTA NETO (1988), o número de elementos sorteados em cada estrato é proporcional ao número de elementos existentes no estrato, fornecendo assim, uma amostra mais representativa da população. Portanto, neste trabalho a divisão do conjunto de dados foi feita três vezes e aleatoriamente dentro de cada classe, respeitando-se a proporcionalidade (representatividade) de cada uma das classes dentro do conjunto total, conforme apresentado na Tabela 5.3.

A fase de treinamento inicia quando os exemplos são apresentados à rede e termina quando todas as conexões estão devidamente ajustadas (treinadas) para reconhecerem todos (ou pelo menos uma boa parte) os exemplos mostrados a ela. A partir desse momento, a RNA está pronta para a fase de teste. A rede deverá ser capaz de reconhecer padrões e generalizá-los para as classes. Nessa fase as RNAs são simuladas com inúmeras arquiteturas diferentes, onde o número de camadas intermediárias e o número de neurônios por camada foram definidos experimentalmente, adotando-se as que apresentaram melhores resultados.

Tabela 5.3: Divisão dos conjuntos de treinamento, teste e validação em função de cada classe pedológica.

Classe Pedológica	Número de amostras	Treinamento (50%)	Teste (25%)	Validação (25%)
LV	35	17	9	9
LR	22	10	6	6
AQ	17	9	4	4
LE	16	8	4	4
Li	5	3	1	1
PV	4	2	1	1
TE	2	1	1	-
TOTAL	101	50	26	25

Após o processo de aprendizado das RNAs, os resultados de cada propriedade mecânica e hidráulica dos solos prevista e obtida no processo de validação foram tratados estatisticamente, utilizando o aplicativo *EXCEL (Microsoft Office 97)*, para testá-los em relação aos resultados reais (ensaios laboratoriais). Foram feitos gráficos com os resultados das propriedades reais *versus* os resultados das RNAs; foram realizadas regressões lineares e estabelecidos os coeficientes de determinação (R^2), calculou-se também os erros médios relativos (EMR), conforme a expressão 5.1, apresentada a seguir.

$$EMR = \frac{\left[\left(\sum \frac{|P_{Real} - P_{RNA}|}{P_{Real}} \right) \cdot 100 \right]}{n} \quad (5.1)$$

onde:

EMR: erro médio relativo;

P_{Real} : valor real da propriedade do solo (ensaios laboratoriais);

P_{RNA} : valor previsto da propriedade pela RNA;

n: número de amostras utilizados no processo de validação da RNA

5.4. SIMULADOR *EASYNN* 7.5

O aplicativo utilizado para simular as RNAs foi o *EASYNN* 7.5, desenvolvido por WOLSTENHOLME (2001). Este simulador é de fácil aplicação, sendo composto por ícones que facilitam o dimensionamento das RNAs, como mostra a Figura 5.2.

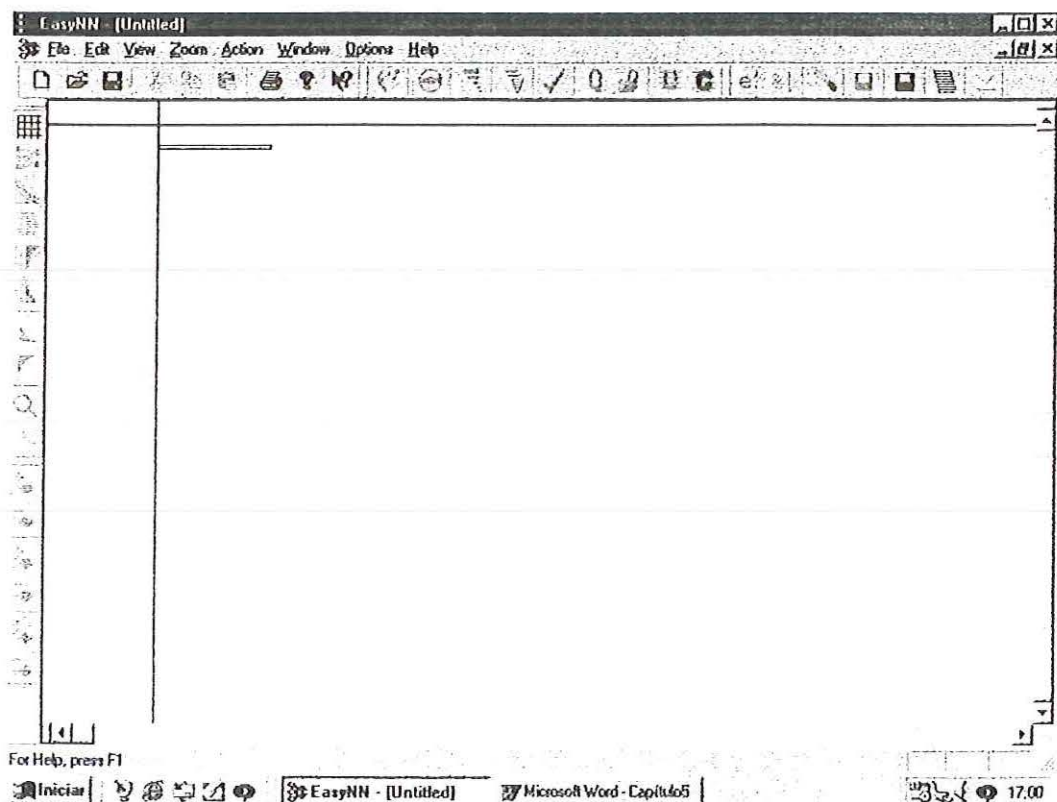


Figura 5.2: Tela de entrada do aplicativo *EASYNN* 7.5.

No *EASYNN* 7.5, as camadas intermediárias e os neurônios que as compõem, podem ser formados automaticamente pelo aplicativo ou manualmente, admitindo no

máximo três camadas intermediárias. A função de ativação é do tipo sigmóide. Os dados para a formação dos arquivos para o processo de aprendizagem (.tvq) podem ser gerados com base em arquivos texto utilizando o *Convert file* no menu Arquivo e *Paste text* no Editar. Este aplicativo gera como saídas um arquivo tipo texto, com todos os resultados do conjunto de validação (.query), o gráfico de erro (exibindo os erros máximo, médio e mínimo obtidos no processo de aprendizagem) e os valores dos pesos e conexões, entre outros parâmetros.

CAPÍTULO 6: APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

6.1. INTRODUÇÃO

Neste capítulo são apresentados as classificações geotécnicas (MCT e HRB), pela adsorção de azul de metileno e por cores (*Munsell Soil Color Charts*) das amostras estudadas, assim como os resultados da variação das seis principais propriedades geotécnicas (umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR após 24 h de imersão obtido na umidade ótima, expansão obtida na umidade ótima e contração obtida na umidade ótima) em função das energias de compactação normal e intermediária e codificados segundo a classe MCT.

As propriedades tecnológicas são representadas, graficamente, em função do valor de azul. Utilizou-se a técnica de regressão simples para estabelecer equações que permitem estimar o valor das propriedades estudadas, conhecido o valor de azul. Também foi utilizada a técnica de regressão múltipla para estimar cada uma das propriedades em função dos valores das outras propriedades.

Foram geradas RNAs para as seis propriedades obtidas tanto nas energias normal como na intermediária. No treinamento das RNAs foi utilizada a base de dados com os resultados de ensaios de cento e uma amostras de solos, contendo umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR após 24 h de imersão obtido na umidade ótima, expansão e contração nas energias normal e intermediária, valor de azul (V_a), coeficiente de atividade (CA), porcentagem de solo passando nas peneiras #0,42, #0,074 e #0,005, parâmetros da classificação MCT (c' , P_i , d' e e') e classificação por cores (croma, valor e matiz).

Para cada combinação de propriedades utilizadas para avaliar outra propriedade do solo são apresentados: a melhor RNA obtida durante as fases de treinamento, teste e validação e, para os subconjuntos de dados utilizados na fase de validação das redes, gráficos com os valores reais das propriedades dos solos (ensaios laboratoriais) *versus* os previstos pelas RNAs, acrescidos das retas de regressão para a RNA que apresentou o coeficiente de determinação máximo ($R^2_{m\acute{a}x}$) e a que apresentou o erro médio relativo mínimo ($EMR_{m\acute{m}n}$).

Além disso, com a finalidade de estimar as propriedades tecnológicas dos solos, foram desenvolvidas equações de regressões com os mesmos dados utilizados no treinamento das redes. Nesses casos, a variável dependente (uma das propriedades em estudo) é prevista com base nas variáveis correlatas (as independentes), através de regressões múltiplas. Nesse caso optou-se por mostrar para cada propriedade estimada, as equações e os respectivos coeficiente de determinação (R^2). Os modelos de regressão múltipla apresentados utilizam os mesmos parâmetros usados nas RNAs com $R^2_{m\acute{a}x}$ e $EMR_{m\acute{m}n}$, obtidas durante as fases de treinamento, teste e validação para cada propriedade.

6.2. RESULTADOS DAS CLASSIFICAÇÕES GEOTÉCNICAS (MCT E HRB), PELA ADSORÇÃO DE AZUL DE METILENO E POR CORES (MUNSELL SOIL COLOR CHARTS)

6.2.1. DISTRIBUIÇÃO DAS AMOSTRAS SEGUNDO A CLASSE MCT E A CLASSE PEDOLÓGICA

Foram utilizadas cento e uma amostras de solos do município de São Carlos, conforme já explicitado no Capítulo 5. Essas amostras pertencem a diversas classes pedológicas. Na Figura 6.1 são apresentadas as posições das amostras dos solos no ábaco MCT e na Tabela 6.1 o resumo das classes MCT *versus* as classes pedológicas.




Figura 6.1: Localização das amostras no ábaco da Classificação MCT, codificadas pela classe pedológica.

Tabela 6.1 – Distribuição das amostras segundo as classes pedológicas e MCT.

		Classe MCT						Total	
		LA	LA'	LG'	NA	NA'	NS'		NG'
Classe pedológica	LV	-	20	11	01	02	-	01	35
	LR	-	05	14	-	-	02	01	22
	AQ	02	03	-	08	04	-	-	17
	LE	-	03	09	-	04	-	-	16
	Li	-	-	-	-	01	04	-	05
	PV	-	-	01	-	01	01	01	04
	TE	-	-	02	-	-	-	-	02
	Total	02	31	37	09	12	07	03	101

Observando-se a Tabela 6.1 e a Figura 6.1, pode-se constatar que, segundo a classificação MCT, a amostragem não foi homogênea, existindo classes com número de amostras significativamente superior às demais. Como exemplo, têm-se as classes LG' e LA' (solos argilosos e arenosos de comportamento laterítico) quando comparada à classe LA, de mesmo comportamento típico, ou às de comportamento não laterítico, como a NG', NS', etc.

6.2.2. CLASSIFICAÇÕES HRB *VERSUS* MCT

Os resultados das classificações MCT e HRB são apresentados, respectivamente, nos Anexos A e B. Na Tabela 6.2 são apresentados os resultados das classificações MCT *versus* HRB, onde podem ser observadas as incidências de uma classe de uma classificação em relação à outra classificação.

A classificação HRB apresenta informações qualitativas sobre o comportamento do material como subleito. Porém, essa classificação possui o inconveniente de, muitas vezes, atribuir o mesmo adjetivo a classes de solos que apresentam desempenhos diferentes quando empregados na execução de subleito de estradas.

A classificação MCT apresenta uma maneira diferenciada de classificar solos. Ao invés de classificá-los por meio de atribuição de adjetivo, indica uma ordem de preferência para os diferentes empregos em pavimentação, tais como: base de pavimento, reforço do subleito, subleito compactado, aterro compactado, proteção à erosão e revestimento primário.

Tabela 6.2 – Resultados da classificação HRB codificados segundo a classe MCT, para os solos de comportamento laterítico e não laterítico.

MCT HRB	Comportamento laterítico			Comportamento não laterítico			
	LA	LA'	LG'	NA	NA'	NG'	NS'
A-1-a	-	-	-	-	-	-	-
A-1-b	-	-	2	-	-	-	-
A-3	-	-	-	-	-	-	-
A-2-4	2	9	1	-	3	-	-
A-2-5	-	-	-	-	-	-	-
A-2-6	-	12	-	8	6	-	5
A-2-7	-	2	-	-	-	-	-
A-4	-	3	15	-	-	-	-
A-5	-	-	-	-	-	-	-
A-6	-	5	9	1	3	1	1
A-7-5	-	-	6	-	-	-	-
A-7-6	-	-	4	-	-	2	1
TOTAL	2	31	37	9	12	3	7

Conforme mostrado na Tabela 4.2, a classificação MCT classifica os materiais em ordem de preferência para diferentes usos em pavimentação. Já a classificação HRB apresenta apenas duas categorias de qualificação de solos como subleito, atribuindo às classes A-1-a, A-1-b, A-3, A-2-4, A-2-5, A-2-6 e A-2-7 comportamento de excelente a bom, e às classes A-4, A-5, A-6, A-7-5 e A-7-6 comportamento de fraco a pobre. A forma adotada para atribuição de adjetivos às classes de solos fundamenta-se em informações sobre a granulometria e nos valores de limite de liquidez e de plasticidade dos solos.

Observando-se a Tabela 6.2, percebe-se que quarenta e duas amostras de solo considerados de comportamento laterítico (MCT) apresentaram resultados piores pela Classificação HRB (comportamento de fraco a pobre). Segundo NOGAMI e VILLIBOR (1993) essa classificação tende a atribuir a esse tipo de solo comportamento inferior ao que realmente possui quando compactado. Já a maioria

dos solos classificados como não lateríticos (71%) foram considerados de melhor qualidade pela classificação HRB.

6.2.3. CLASSIFICAÇÃO DOS SOLOS POR ADSORÇÃO DE AZUL DE METILENO *VERSUS* MCT

Os valores de azul (V_a) e os coeficientes de atividade (CA) obtidos para cada uma das amostras de solos juntamente com seus respectivos graus de atividade são apresentados no Anexo C. A Figura 6.2 mostra a localização dos solos estudados no ábaco proposto por FABBRI (1994). As amostras encontram-se codificadas segundo sua classe na MCT.

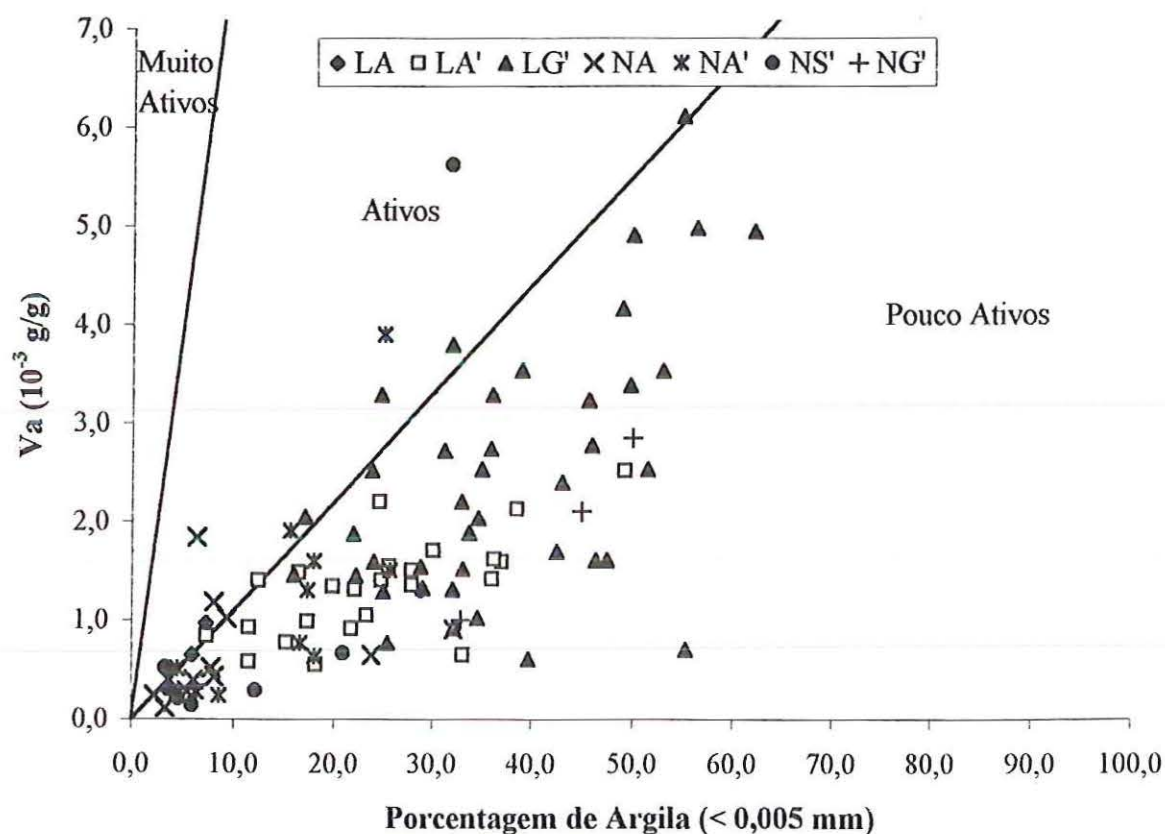


Figura 6.2 – Localização dos solos estudados no ábaco proposto por FABBRI (1994), codificados segundo a classe MCT.

Esse autor, conforme discutido no Capítulo 4, definiu três graus de atividade para os grupos de argilo-minerais, segundo seus coeficientes de atividade, a saber: muito

ativos ($CA > 80$), ativos ($11 < CA < 80$) e pouco ativos ($CA < 11$). Cabe ressaltar que os solos de comportamento laterítico, segundo a MCT, têm a tendência de se situarem abaixo da linha correspondente a $CA = 11$ e, os de comportamento não laterítico, acima desta linha.

Ainda analisando a Figura 6.2 observa-se que segundo os resultados da adsorção de azul de metileno:

- a) não há nenhuma amostra com argilo-minerais muito ativos, pois os CAs variaram de 1,27 a 28,72 g/g%;
- b) grande parte das amostras (83,2%) foram classificadas como pouco ativas e o restante (16,8%) como ativas;
- c) oito amostras de comportamento laterítico acusaram atividades de argilo-minerais dos grupos das caulinitas e/ou ilitas (ativos). Para essas amostras, os CAs variaram de 11,1 a 13,3 g/g%, valores esses próximos da linha divisória entre ativos e pouco ativos. Deve-se ressaltar que essas amostras ocupam posição no ábaco de classificação MCT bastante próximas da linha divisória entre comportamento laterítico e não laterítico;
- d) há vinte e três amostra (22,8% do total) de comportamento não laterítico cuja atividade obtida foi compatível com a dos solos de comportamento laterítico ($CA < 11$). Destas amostras, seis encontram-se próximas da linha divisória entre solos de comportamento laterítico e não laterítico da MCT;
- e) cerca de 70% das amostras mostraram que há concordância entre os resultados da classificação MCT e os da adsorção de azul de metileno.

6.2.4. CLASSIFICAÇÃO DOS SOLOS POR CORES

Os resultados da identificação das cores dos solos, usando-se a Escala *Munsell* de Cores para Solos (*Munsell Soil Color Charts*, 1975) estão apresentados no Anexo D.

Neste item apresenta-se, na Tabela 6.3, os resultados da designação das cores codificadas segundo as classes pedológicas dos solos. Nessa tabela constam as três variáveis, o matiz (*hue*), o valor (*value*) e o croma (*chroma*), juntamente com a classe pedológica e o número de amostras encontrado para cada classe.

Tabela 6.3: Classificação por cores (*Munsell Soil Color Charts*, 1975) segundo o número de amostras por classe pedológica.

matiz	valor	croma	LV	LR	AQ	LE	Li	PV	TE
10 YR	7	6	1	-	-	-	-	-	-
10 YR	7	4	-	-	1	-	-	-	-
10 YR	7	3	-	-	-	-	1	-	-
10 YR	6	6	2	-	1	-	-	-	-
10 YR	6	4	5	-	2	-	3	-	-
10 YR	6	3	1	-	-	-	-	-	-
10 YR	5	3	1	-	1	-	1	-	-
10 YR	5	2	-	-	-	1	-	1	-
2,5 YR	5	6	-	1	-	-	-	-	-
2,5 YR	5	4	2	-	-	1	-	-	-
2,5 YR	5	2	1	-	-	-	-	-	-
2,5 YR	4	4	2	7	-	-	-	-	-
2,5 YR	4	2	1	1	-	-	-	-	-
2,5 YR	3	6	-	2	-	-	-	-	-
2,5 YR	3	4	2	7	-	1	-	-	-
2,5 YR	2,5	4	-	2	-	-	-	-	-
5 YR	7	3	1	-	-	-	-	-	-
5 YR	6	6	-	-	1	-	-	-	-
5 YR	6	4	1	1	1	-	2	1	-
5 YR	6	3	-	-	-	1	-	-	-
5 YR	5	6	1	-	1	-	-	-	-
5 YR	5	4	6	1	1	-	-	2	-
5 YR	5	3	2	-	5	6	-	-	-
5 YR	4	4	1	-	-	-	-	-	1
5 YR	4	3	1	-	1	3	-	-	1
5 YR	4	2	-	-	1	-	-	-	-
5 YR	3	4	-	-	-	1	-	-	-
5 YR	3	3	-	-	-	1	-	-	-
7,5 YR	6	4	2	-	-	-	-	-	-
7,5 YR	5	4	2	-	-	1	-	-	-
7,5 YR	5	2	-	-	1	-	-	-	-

Observa-se, através da Tabela 6.3, que:

- os latossolos vermelho-amarelos (LV) apresentam intensa variação de cores, devido à maior incidência de amostras no universo estudado e a coleta ter ocorrido em vários pontos do município;
- cerca de 91% (vinte) das amostras de latossolo roxo (LR) foram classificadas no matiz 2,5 YR, tendência esta confirmada por OLIVEIRA *et al.* (1984), que descreve os LR encontrados no município de São Carlos como originários de

- basaltos e diabásios, de textura argilosa ou muito argilosa, predominando os solos com pouca areia grossa (menos de 10%), profundos, de coloração vermelho escuro a bruno avermelhado e teor de Fe_2O_3 variando entre 18 e 36%;
- c) a maior parte das amostras (65%) de areia quartzosa profunda (AQ) foram classificadas em 5YR e outras 29% como 10YR variando o croma e o valor;
- d) os latossolos vermelho-escuros (LE) apresentaram 75% das amostras (doze amostras) com matiz igual a 5YR, com algumas diferenças entre o valor e o croma. Esses solos, conforme PRADO (1993), apresentam altos teores de argila (maior que 35%) e teores de Fe_2O_3 entre 8 e 18%, com coloração vermelho escuro a bruno avermelhado;
- e) os solos litólicos, provenientes das proximidades do Rio Moji-Guaçu, apresentam-se com uma cor acinzentada com manchas esverdeadas, sendo mal drenados, com períodos de seca e cheia; na maior parte das vezes classificados com matiz 10 YR variando o valor e o croma;
- f) três amostras de podzólico vermelho-amarelo (PV) foram classificadas pelo matiz 5YR e uma por 10YR;
- g) as duas amostras de terra roxa estruturada (TE) foram classificadas como 5YR 4/4 e 5YR 4/3, respectivamente, bruno-escuro e bruno-avermelhado-escuro.

6.3. PROPRIEDADES GEOTÉCNICAS DE INTERESSE

6.3.1. MASSA ESPECÍFICA DOS SÓLIDOS

Os valores da massa específica dos sólidos obtidos para as amostras de solos são apresentados no Anexo A. Na Tabela 6.4, mostram-se os resultados codificados pela classe MCT, onde constam os valores mínimos, máximos e médios e desvios padrões para o conjunto de ensaios.

Observa-se que, de acordo com esta tabela, a massa específica dos sólidos variou entre $2,310 \text{ g/cm}^3$ e $3,082 \text{ g/cm}^3$. Note-se que seu valor é menor para os solos classificados como areias lateríticas (LA) e maior para os classificados como solos argilosos lateríticos (LG'), o que era de se esperar uma vez que nos solos argilosos lateríticos contém elevada quantidade de óxidos e hidróxidos de ferro e alumínio.

Tabela 6.4 – Variação dos valores da massa específica dos sólidos das amostras estudadas.

Classe MCT	Número de amostras	Valores			
		Mínimo (g/cm ³)	Máximo (g/cm ³)	Médio (g/cm ³)	Desvio (g/cm ³)
LA	02	2,624	2,611	2,618	0,009
LA'	31	2,310	2,977	2,663	0,118
LG'	37	2,369	3,082	2,731	0,149
NA	09	2,583	2,718	2,637	0,049
NA'	12	2,407	3,053	2,702	0,185
NS'	07	2,494	2,855	2,651	0,143
NG'	03	2,551	2,724	2,654	0,091
Total	101	2,310	3,082	2,687	0,132

6.3.2. GRANULOMETRIA

Os resultados das análises granulométricas por sedimentação dos solos estudados são apresentados no Anexo E.

6.3.3. LIMITE DE LIQUIDEZ E LIMITE DE PLASTICIDADE

Os valores de limite de liquidez, limite de plasticidade e índice de plasticidade são mostrados no Anexo F. Percebe-se que a maioria dos solos classificados como areia quartzosa, com exceção da amostra 18, e todos os solos litólicos são não plásticos, o que é razoável pois se tratam de solos que apresentam pequena quantidade de material na fração fina.

6.3.4. MINI-CBR, EXPANSÃO E CONTRAÇÃO OBTIDOS NA UMIDADE ÓTIMA

Os ensaios de mini-CBR, expansão e contração obtidos na umidade ótima foram realizados nas energias normal e intermediária e os resultados, para todos os solos estudados, encontram-se nos anexos G (energia normal) e H (energia intermediária). As propriedades analisadas são: umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR após 24 h

de imersão obtido na umidade ótima, expansão obtida na umidade ótima e contração obtida na umidade ótima.

6.3.4.1. UMIDADE ÓTIMA

Os resultados de variação da umidade ótima em função das energias de compactação normal e intermediária e codificados segundo a classe MCT, para os solos estudados, encontram-se apresentados, respectivamente, nas Figura 6.3 e 6.4.

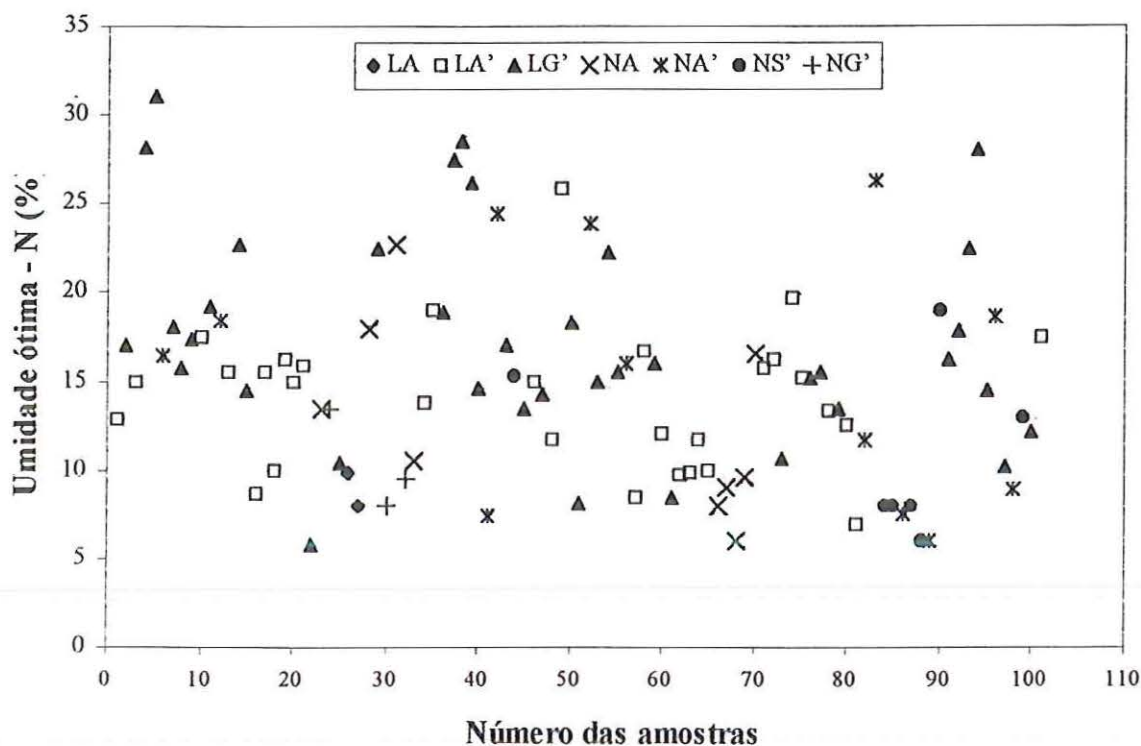


Figura 6.3 – Valores das umidades ótimas na energia normal para os solos estudados, codificados segundo a classe MCT.

Observa-se nas Figuras 6.3 e 6.4, que a umidade ótima na energia normal e intermediária variou, respectivamente, entre 5,80 e 31,04 % e 4,36 e 26,50 %.




Figura 6.4 – Valores das umidades ótimas na energia intermediária para os solos estudados, codificados segundo a classe MCT.

6.3.4.2. MASSA ESPECÍFICA SECA MÁXIMA

Os valores das massas específicas secas máximas, codificados segundo a classe MCT, são apresentadas nas Figuras 6.5 e 6.6, respectivamente, para as energias normal e intermediária.

Nas Figuras 6.5 e 6.6 pode-se observar que a massa específica seca máxima na energia normal e intermediária variou, respectivamente, entre 1,446 e 2,028 g/cm³ e 1,451 e 2,242 g/cm³.




Figura 6.5 – Valores das massas específicas secas máximas na energia normal para os solos estudados, codificados segundo a classe MCT.




Figura 6.6 – Valores das massas específicas secas máximas na energia intermediária para os solos estudados, codificados segundo a classe MCT.

6.3.4.3. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA

Os resultados dos ensaios de Mini-CBR na umidade de moldagem obtidos nas umidades ótimas (Mini-CBR-Hm), codificados segundo a classe MCT, são apresentados nas Figuras 6.7 e 6.8, respectivamente, para as energias normal e intermediária.

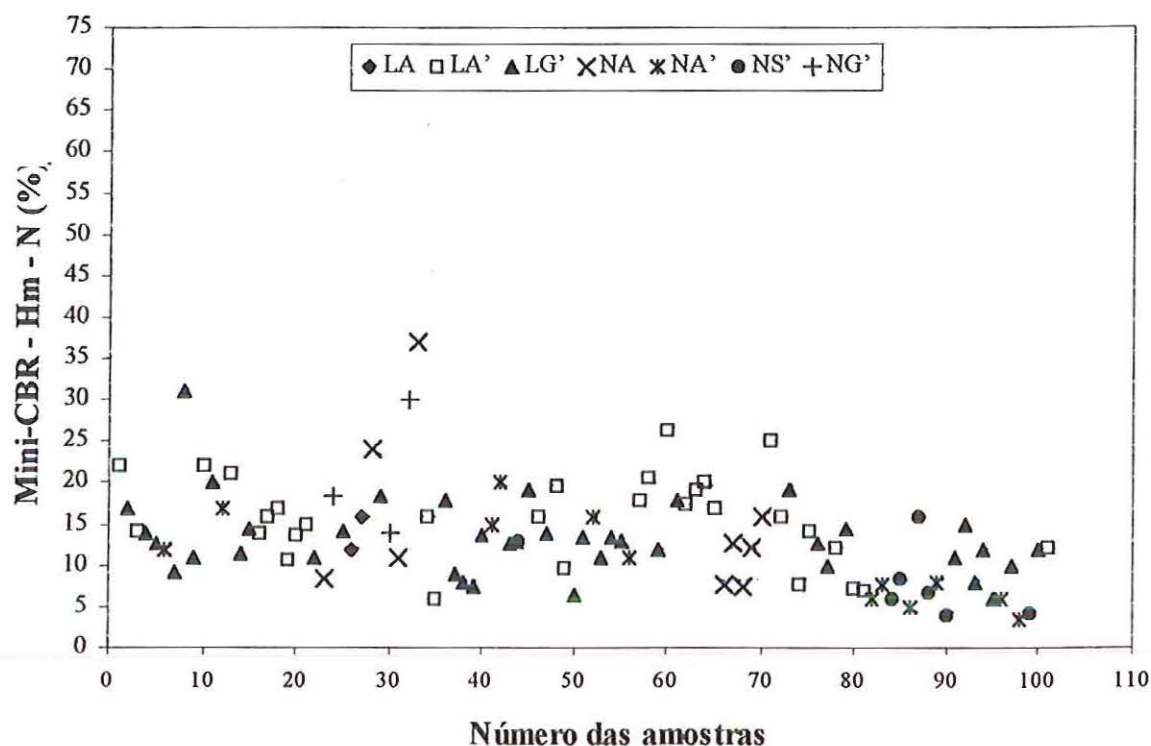


Figura 6.7 – Valores de Mini-CBR na umidade de moldagem obtidos nas umidades ótimas para os solos estudados na energia normal, codificados segundo a classe MCT.

Observa-se, de acordo com as Figuras 6.7 e 6.8, que os valores de Mini-CBR na umidade de moldagem obtidos nas umidades ótimas na energia normal e intermediária variaram, respectivamente, entre 3,50 e 37,10 % e 5,50 e 71,10 %.




Figura 6.8 – Valores de Mini-CBR na umidade de moldagem obtidos nas umidades ótimas para os solos estudados na energia intermediária, codificados segundo a classe MCT.

6.3.4.4. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA

Os resultados dos ensaios de Mini-CBR após 24 h de imersão obtidos nas umidades ótimas (Mini-CBR-24h), codificados segundo a classe MCT, são apresentados nas Figuras 6.9 e 6.10, respectivamente, para as energias normal e intermediária.

As Figuras 6.9 e 6.10 apresentam os valores de Mini-CBR após 24 h de imersão obtidos nas umidades ótimas para as energias de compactação normal e intermediária que variaram, respectivamente, entre 2,00 e 22,70 (%) e 2,80 e 42,80 (%). Observa-se que os menores valores são os dos solos classificados como siltosos não lateríticos (NS'), tanto para a energia normal como para a intermediária e os maiores, para os solos classificados como areias não lateríticas (NA) na energia normal e como arenosos lateríticos (LA') na energia intermediária.




Figura 6.9 – Valores do Mini-CBR após 24 h de imersão obtidos nas umidades ótimas para os solos estudados na energia normal, codificados segundo a classe MCT.




Figura 6.10 – Valores do Mini-CBR após 24 h de imersão obtidos nas umidades ótimas para os solos estudados na energia intermediária, codificados segundo a classe MCT.

6.3.4.5. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA

Os resultados dos ensaios de expansão obtidos nas umidades ótimas, codificados segundo a classe MCT, são apresentados nas Figuras 6.11 e 6.12, respectivamente, para as energias normal e intermediária.




Figura 6.11 – Valores de expansão obtidos nas umidades ótimas para os solos estudados na energia normal, codificados segundo a classe MCT.

Observa-se, de acordo com as Figuras 6.11 e 6.12, que a expansão obtida na umidade ótima na energia normal e intermediária variou, respectivamente, entre 0,00 e 1,16 % e 0,00 e 0,90 %.

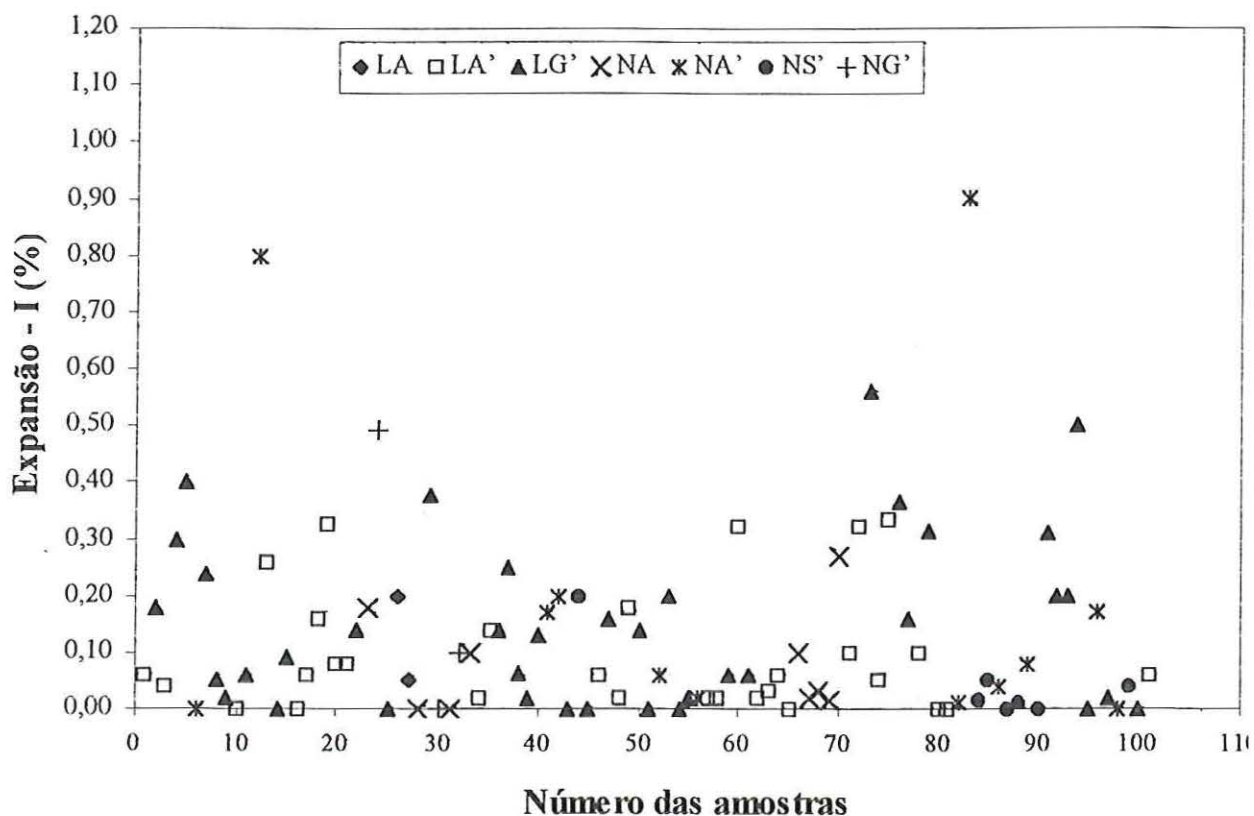


Figura 6.12 – Valores de expansão obtidos nas unidades ótimas para os solos estudados na energia intermediária, codificados segundo a classe MCT.

6.3.4.6. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA

Os resultados dos ensaios de contração obtidos nas unidades ótimas, codificados segundo a classe MCT, são apresentados nas Figuras 6.13 e 6.14, respectivamente, para as energias normal e intermediária.

Observa-se, de acordo com as Figuras 6.13 e 6.14, que as contrações obtidas nas unidades ótimas nas energias normal e intermediária variaram, respectivamente, entre 0,03 e 2,22 % e 0,02 e 2,50 %.




Figura 6.13 – Valores de contração obtidos nas umidades ótimas para os solos estudados na energia normal, codificados segundo a classe MCT.




Figura 6.14 – Valores de contração obtidos nas umidades ótimas para os solos estudados na energia intermediária, codificados segundo a classe MCT.

6.4. COMPARAÇÃO ENTRE A PREVISÃO DE PROPRIEDADES DOS SOLOS DA CLASSIFICAÇÃO MCT E OS RESULTADOS OBTIDOS EM LABORATÓRIOS

A seguir, faz-se uma comparação entre a previsão de propriedades dos solos fornecidas pela classificação MCT para as condições de energia normal (Tabela 4.2) e os valores obtidos em laboratório na mesma energia de compactação (mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão, expansão e contração obtidos nas umidades ótimas). A verificação da concordância entre resultados previstos pela Classificação MCT e os obtidos em laboratório, para as amostras estudadas, são apresentados no Anexo I.

Considerando-se as previsões de propriedades dadas pela MCT, 29,7% dos valores de mini-CBR na umidade de moldagem obtidos em laboratório apresentaram discordância, sendo quinze da classe LG', sete da NA', quatro da LA', duas da NG'; uma NA e uma NS'. Para os valores de mini-CBR após 24 h de imersão, os resultados de laboratório discordaram em 58,4% da previsão de propriedades obtida da MCT, sendo nesse caso trinta e cinco LG', dezessete LA', duas LA, duas NA', duas NG' e uma NA.

Os resultados de laboratório para os ensaios de expansão e contração mostraram uma menor discordância em relação às previsões da MCT, sendo de 11,9% para a expansão (sete NS', duas NG' e uma LA', LG', NA') e de 10,9% para a contração (sete LG' e quatro NS').

Na Tabela 6.5 apresentam-se trinta e uma amostras que discordaram em duas ou três propriedades em relação aos valores previstos pela Classificação MCT e os obtidos em laboratório.

Observa-se que do conjunto de amostras com resultados divergentes em relação aos previstos pela Classificação MCT, para duas ou três propriedades, aproximadamente 61,3% das amostras eram solos argilosos lateríticos (LG'). Cabe ressaltar que essa classe de solo corresponde a 36,6% do total de amostras estudadas.

Tabela 6.5 – Amostras que apresentam discordância em duas ou três propriedades em relação aos valores previstos pela Classificação MCT.

Número da amostra	Classe MCT	Propriedades que discordaram
23, 31	NG'	mini-CBR na umidade de moldagem
94	LG'	mini-CBR após 24 h de imersão expansão
99	LG'	mini-CBR na umidade de moldagem mini-CBR após 24 h de imersão contração
98	NS'	mini-CBR na umidade de moldagem expansão e contração
14, 35, 37, 38, 39, 49, 50, 53, 74, 90, 91, 93, 96	LG'	mini-CBR na umidade de moldagem
9, 56, 77, 80	LA'	mini-CBR após 24 h de imersão
82, 85	NA'	
44, 46, 60, 72,	LG'	mini-CBR após 24 h de imersão contração
86, 87, 89	NS'	expansão e contração

6.5. RELAÇÃO ENTRE AS PROPRIEDADES GEOTÉCNICAS E O VALOR DE AZUL (Va)

Os valores de azul (Va) de todas as amostras são apresentados no Anexo C. As relações entre as variáveis estudadas e o Va foram identificadas por meio da técnica de regressão linear simples, obtendo-se equações que podem ser usadas para estimar os valores das propriedades, conhecidos os valores de azul. Os resultados são mostrados em gráficos juntamente com os pontos originais e os respectivos coeficientes de determinação (R^2) para cada modelo.

Foram realizados doze modelos de regressão linear simples com todas as variáveis de interesse (umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão, expansão e contração obtidos nas

umidades ótimas) para as duas energias de compactação em função do V_a , porém apenas quatro modelos apresentaram resultados razoáveis e são discutidos, ou seja, os outros oito modelos apresentaram os valores dos coeficientes de determinação menores que 0,5 e estão apresentados no Anexo J. COSTA NETO (1988) observa que coeficientes de determinação (R^2) menor que 0,5 significa que a regressão não consegue explicar nem a metade da variação da variável dependente (propriedade tecnológica do solo no caso).

A seguir são mostrados os resultados das regressões que apresentaram coeficientes de determinação (R^2) maior que 0,5.

6.5.1. UMIDADE ÓTIMA *VERSUS* VALOR DE AZUL

As relações entre a umidade ótima e o valor de azul para os solos estudados, para as energias de compactação normal e intermediária, são mostradas nas Figuras 6.15 e 6.16, assim como as equações que descrevem essas relações e os respectivos coeficientes de determinação (R^2).




Figura 6.15 – Relação entre a umidade ótima na energia normal e o valor de azul.






Figura 6.16 – Relação entre a umidade ótima na energia intermediária e o valor de azul.

Note-se que aproximadamente 67% e 63% das variações dos valores das umidades ótimas, respectivamente, para a energia normal e intermediária, podem ser explicadas pela variação do valor de azul (Va). As Figuras 6.15 e 6.16 mostram que há uma tendência de o valor de umidade ótima crescer com o aumento do valor de Va. A partir das equações fornecidas pode-se estimar, no universo em estudo, o valor da umidade ótima quando se conhece o valor de azul.

6.5.2. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA *VERSUS* VALOR DE AZUL

As relações entre a contração obtida na umidade ótima e o valor de azul para os solos estudados, nas energias de compactação normal e intermediária, são mostradas nas figuras 6.17 e 6.18. A partir da análise dessas figuras pode-se observar que a contração aumenta com o valor de azul. Os coeficientes de determinação são iguais a 0,59 e 0,50, respectivamente, para a energia normal e intermediária.




Figura 6.17 – Relação entre a contração obtida na umidade ótima na energia normal e o valor de azul.




Figura 6.18 – Relação entre a contração obtida na umidade ótima na energia intermediária e o valor de azul.

6.6. VARIACÕES DOS VALORES DAS PROPRIEDADES EM FUNÇÃO DA ENERGIA DE COMPACTAÇÃO

Neste item, apresenta-se uma comparação das propriedades tecnológicas (umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão, expansão e contração) dos solos obtidas na umidade ótima, em função de energias de compactação normal e intermediária. Assim, são realizadas a apresentação e a análise dos dados através de gráficos em que se representam, em abcissas, as propriedades na energia normal, e em ordenadas as propriedades na energia intermediária.

As Figuras 6.19 a 6.24 mostram as equações de regressão e os coeficientes de determinação (R^2) obtidos para as propriedades tecnológicas de interesse nas energias de compactação normal *versus* intermediária.

6.6.1. UMIDADE ÓTIMA NA ENERGIA NORMAL *VERSUS* UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA




Figura 6.19 – Umidade ótima na energia normal *versus* umidade ótima na energia intermediária.

Da regressão linear simples resultou um coeficiente de determinação de 0,97, ou seja, existe uma boa correlação entre a umidade ótima na energia normal e a umidade ótima na energia intermediária. A partir dessa equação de regressão pode-se estimar, no universo em estudo, o valor da umidade ótima em uma energia quando se conhece o valor da outra energia.

6.6.2. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA NORMAL *VERSUS* MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA INTERMEDIÁRIA




Figura 6.20 –Massa específica seca máxima na energia normal *versus* massa específica seca máxima na energia intermediária.

Da regressão linear entre as duas massas específicas secas observa-se um coeficiente de determinação de 0,68, ou seja, aproximadamente 68% dos valores das massas específicas secas máximas na energia intermediária pode ser explicados pelos valores das massas específicas secas máximas na energia normal.

6.6.3. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL *VERSUS* MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA




Figura 6.21 –Mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal *versus* mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária.

Note-se que a regressão linear resultou em um coeficiente de determinação de 0,51, ou seja, aproximadamente 51% dos valores dos mini-CBRs na umidade de moldagem obtido na umidade ótima na energia normal podem ser explicados pelos valores dos mini-CBRs na umidade de moldagem obtido na umidade ótima na energia intermediária.

6.6.4. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL *VERSUS* MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA




Figura 6.22 –Mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal e o mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária.

O valor do coeficiente de determinação (R^2) obtido através de regressão linear para os mini-CBR após 24 h de imersão nas energias normal e intermediária foi 0,46. Este coeficiente baixo ($R^2 \leq 0,5$) significa que, aproximadamente 54% dos valores dos mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária não podem ser explicados pelos valores dos mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal.

6.6.5. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL VERSUS EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

Observa-se, pela Figura 6.23, que a relação entre a expansão na energia normal e na energia intermediária para os solos estudados não é clara, apresentando um coeficiente de determinação de 0,26. Este coeficiente mostra uma má correlação entre as expansões nas energias normal e intermediária. Esta verificação poderia ser esperada, uma vez que a grandeza das medidas das expansões que neste estudo ficaram entre 0,0 e 1,2% e a dificuldade de se realizar essas leituras com a precisão requerida, dada sua magnitude.




Figura 6.23 – Relação entre as expansões obtidas nas umidades ótimas nas energias normal e intermediária.

6.6.6. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL *VERSUS* CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA




Figura 6.24 – Relação entre as contrações obtidas nas umidades ótimas nas energias normal e intermediária.

Pode-se verificar, pela Figura 6.24, uma boa correlação entre a contração na energia normal e na intermediária, que resultou em um coeficiente de determinação de 0,63.

6.7. REDES NEURAIS ARTIFICIAIS E REGRESSÕES MÚLTIPLAS PARA PREVISÃO DE PROPRIEDADES DOS SOLOS

Conforme já explicitado anteriormente, foram geradas 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 após 24 h de imersão obtido umidade ótima, expansão obtida umidade ótima e contração obtida umidade ótima tanto para a energia normal e como para a 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, coeficiente de atividade, análise granulométrica do solo (#0,42, #0,074 e #0,005), parâmetros da classificação MCT (c' , P_i , d' e e') e classificação por cores (croma, valor e matiz).

Para cada modelo de previsão de propriedades são apresentados: a melhor RNA obtida durante as fases de treinamento, teste e validação e, para os subconjuntos de dados utilizados na fase de validação das redes, gráfico com os valores reais das propriedades do solo (ensaios laboratoriais) *versus* os previstos pelas RNAs, acrescidos das retas de regressão que apresentaram o coeficiente de determinação máximo e também aqueles que apresentaram o erro médio relativo mínimo calculado a partir dos resultados reais e dos estimados pelas RNAs.

Foram simuladas cento e noventa e sete redes neurais artificiais. A seguir são apresentados os resultados das doze RNAs que melhor se adaptaram na simulação da previsão de cada propriedade na energia normal e intermediária considerando o coeficiente de determinação máximo ($R^2_{máx}$) e o erro médio relativo mínimo ($EMR_{mín}$), bem como as equações de regressão obtidas para os mesmos dados utilizados no processo de treinamento das redes. Os demais modelos de RNAs implementados para cada propriedade e as outras equações de regressão estão apresentadas, respectivamente, nos Anexos L e M.

Além disso, também com a finalidade de estimar as propriedades tecnológicas dos solos, foram desenvolvidas equações de regressões múltiplas com os mesmos dados utilizados no treinamento das redes. Nesse caso optou-se por apresentar, para cada propriedade estimada, as equações e os respectivos coeficiente de determinação (R^2) para os casos onde os R^2 obtidos foram maiores ou iguais a 0,5.

Foram desenvolvidas cento e oitenta e uma equações de regressão que combinavam as propriedades entre si para determinar cada propriedade estimada. Nesses casos, as doze variáveis dependentes (umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR após 24 h de imersão obtido umidade ótima, expansão obtida umidade ótima e contração obtida

umidade ótima nas energias normal ou intermediária) são estimadas com base nas vinte e quatro variáveis independentes (umidade ótima, massa específica seca máxima, , mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR após 24 h de imersão obtido umidade ótima, expansão obtida umidade ótima e contração obtida umidade ótima nas energias normal ou intermediária, valor de azul, coeficiente de atividade, análise granulométrica do solo (#0,42, #0,074 e #0,005), parâmetros da Classificação MCT (c' , P_i , d' e e') e Classificação por cores (croma, valor e matiz)). Cabe ressaltar que se o modelo de regressão estiver estimando uma propriedade sujeita a uma energia de compactação, as variáveis correlatas utilizadas foram as da outra energia de compactação.

6.7.1. UMIDADE ÓTIMA

6.7.1.1. UMIDADE ÓTIMA NA ENERGIA NORMAL

A Figura 6.25 apresenta a arquitetura de RNA que, por coincidência, apresentou tanto o R^2_{\max} e como o EMR_{\min} para a previsão da umidade ótima na energia normal. Nela foram utilizadas, além de uma camada de entrada, com três neurônios (umidade ótima e massa específica seca máxima na energia intermediária e coeficiente de atividade), uma camada intermediária, composta de seis neurônios, e a camada de saída com um neurônio (umidade ótima na energia normal).

A Figura 6.26 apresenta os valores de umidade ótima na energia normal previstos pela RNA da Figura 5.25 *versus* os valores reais (ensaios laboratoriais), dos vinte e cinco casos usados na fase de validação da rede. Nela pode ser visualizada a reta de regressão linear obtida a partir desses resultados.

O valor do coeficiente de determinação máximo obtido pela regressão linear para a umidade ótima na energia normal é igual a 0,95. Este coeficiente mostra uma boa correlação entre os valores reais das umidades ótimas na energia normal e os previstos. O erro médio relativo mínimo (EMR_{\min}) para a umidade ótima na energia normal para a RNA foi calculado por meio da expressão 5.1 e o valor obtido foi igual

a 8,22%, o que comprova a potencialidade de utilização das RNAs para esse tipo de previsão.

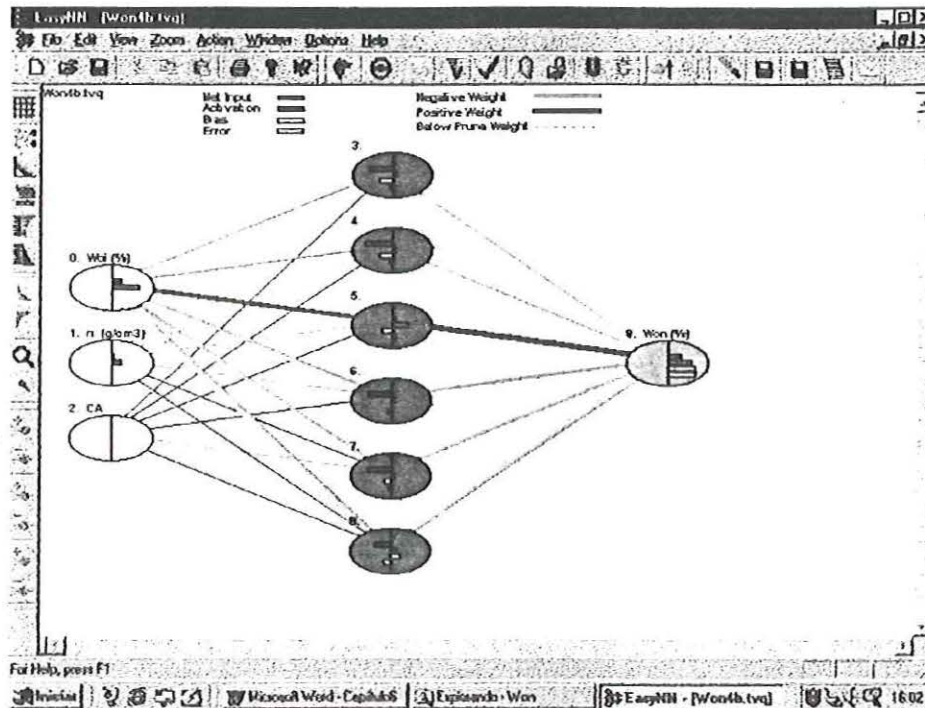


Figura 6.25 – A arquitetura da RNA que apresentou R^2_{\max} e EMR_{\min} , para a previsão da umidade ótima na energia normal.




Figura 6.26 – Valores reais das umidades ótimas na energia normal (ensaios) *versus* os previstos pela RNA.

A expressão 6.1 apresenta a equação de regressão múltipla para determinar a umidade ótima na energia normal, a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação da rede apresentada anteriormente.

$$W_{on} = 1,02W_{oi} + 0,11\pi_i + 0,0004CA + 1,66 \quad (6.1)$$

$$R^2 = 0,97$$

onde:

W_{on} : umidade ótima na energia normal, em %;

W_{oi} : umidade ótima na energia intermediária, em %;

π_i : massa específica seca máxima na energia intermediária, em g/cm^3 ;

CA: coeficiente de atividade, em 10^{-3} g/g\% .

6.7.1.2. UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

A Figura 6.27 apresenta a arquitetura da RNA que alcançou o $R^2_{\text{máx}}$ para a previsão da umidade ótima na energia intermediária. Esta RNA foi composta de uma camada de entrada com três neurônios (umidade ótima e massa específica seca máxima na energia normal e coeficiente de atividade), uma camada intermediária composta de seis neurônios e a camada de saída igual à descrita anteriormente. A RNA que apresentou o $\text{EMR}_{\text{mín}}$ para a mesma saída, tem a camada intermediária com o mesmo número da do modelo anterior (uma camada com seis neurônios), diferenciando-se na camada de entrada, que foi composta com seis neurônios (umidade ótima e massa específica seca máxima na energia normal, coeficiente de atividade e frações do solo passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm), conforme mostra a Figura 6.28.

A Figura 6.29 apresenta os valores de umidade ótima na energia intermediária previstos pelas RNAs apresentadas nas Figuras 6.27 ($R^2_{\text{máx}}$) e 6.28 ($\text{EMR}_{\text{mín}}$) *versus* os valores reais (ensaios laboratoriais) para vinte e cinco casos usados na fase de validação da rede. Nela podem ser visualizadas as retas obtidas a partir de regressões lineares realizadas com esses resultados.

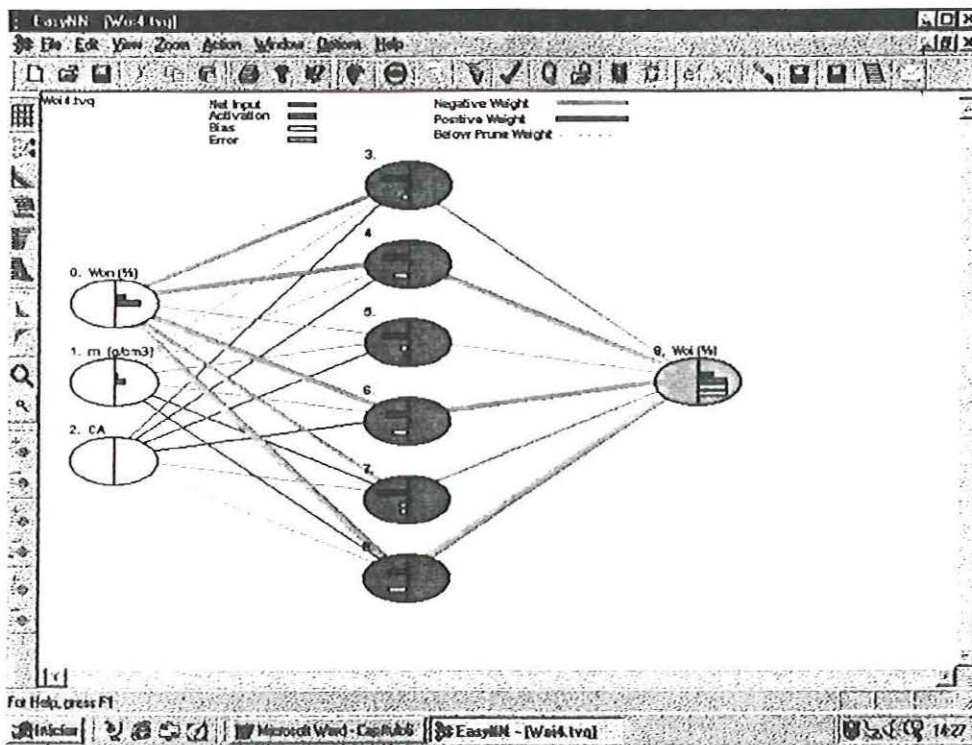


Figura 6.27 – A arquitetura da RNA que apresentou R^2_{\max} para a previsão da umidade ótima na energia intermediária.

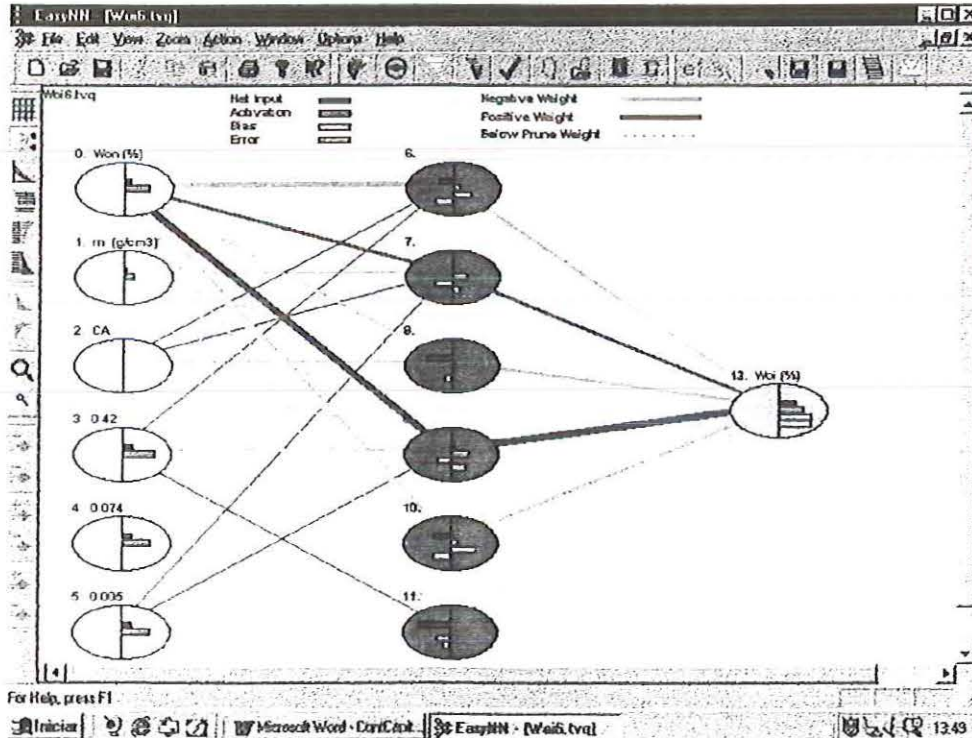


Figura 6.28 – A arquitetura da RNA que apresentou EMR_{\min} para a previsão da umidade ótima na energia intermediária.




Figura 6.29 – Valores reais das umidades ótimas na energia intermediária (ensaios) *versus* os previstos pelas RNAs, para os casos de $R^2_{máx}$ e de $EMR_{mín}$.

O valor do coeficiente de determinação para o caso da RNA de $R^2_{máx}$ encontrado mediante a regressão linear para umidade ótima na energia intermediária foi 0,96. Este coeficiente mostra uma boa correlação entre os valores das umidades ótimas na energia intermediária reais e os previstos. O erro médio relativo mínimo ($EMR_{mín}$) para a umidade ótima na energia intermediária pelo procedimento de RNA foi igual a 9,88% e o valor do coeficiente de determinação obtido da regressão para essa rede foi 0,95.

As expressões 6.2 e 6.3 apresentam, respectivamente, as equações de regressão múltipla e os coeficientes de determinação (R^2) para determinar a umidade ótima na energia intermediária utilizando as mesmas propriedades utilizadas nas duas redes apresentadas anteriormente. Os modelos de regressão foram feitos a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.

$$Woi = 0,94Won - 0,75pn - 0,004CA + 0,13 \quad (6.2)$$

$$R^2 = 0,97$$

$$Woi = 0,86Won - 0,80pn + 0,03CA + 0,01(\#0,42) - 0,005(\#0,074) + \\ + 0,04(\#0,005) - 0,70 \quad (6.3)$$

$$R^2 = 0,97$$

onde:

Woi: umidade ótima na energia intermediária, em %;

Won: umidade ótima na energia normal, em %;

pn: massa específica seca máxima na energia normal, em g/cm^3 ;

CA: coeficiente de atividade, em 10^{-3} g/g\% ;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm (%).

6.7.1.3. COMENTÁRIOS

Os resultados dos procedimentos para as previsões das umidades ótimas nas energias normal e intermediária apresentaram resultados excelentes. Os coeficientes de determinação máximo ($R^2_{\text{máx}}$), as retas de regressão e os erros médios mínimos (EMR_{min}) para estas RNAs (Figuras 6.26 e 6.29) comprovam os seus desempenhos.

As arquiteturas de RNA encontradas para umidade ótima na energia normal, correspondente a $R^2_{\text{máx}}$ e o EMR_{min} (Figura 6.25) e para umidade ótima na energia intermediária, correspondente a $R^2_{\text{máx}}$ (Figura 6.27) apresentaram apenas uma camada intermediária e o mesmo número de neurônios para cada camada, tendo as mesmas variáveis de entrada (umidade ótima e massa específica seca máxima na energia intermediária e coeficiente de atividade). Já a melhor arquitetura de RNA para umidade ótima na energia intermediária (Figura 6.28), correspondente a EMR_{min} diferenciou-se das outras no número de neurônios para a camada intermediária e na necessidade de inclusão de mais três variáveis na camada de entrada (umidade ótima e massa específica seca máxima na energia intermediária, coeficiente de atividade e

as frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm (%)).

Os modelos de regressão correspondentes às RNAs para previsão para umidade ótima na energia normal e intermediária (expressões 6.1, 6.2 e 6.3) apresentaram resultados similares, comprovando o bom desempenho alcançado pelas RNAs para a previsão dessas propriedades.

6.7.2. MASSA ESPECÍFICA SECA MÁXIMA

6.7.2.1. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA NORMAL

A Figura 6.30 mostra a arquitetura da RNA que apresentou o $R^2_{\text{máx}}$ para a previsão da massa específica seca máxima na energia normal. Ela é composta de uma camada de entrada com dois neurônios (umidade ótima e massa específica seca máxima na energia intermediária) e uma camada intermediária composta de quatro neurônios, além da de saída. A Figura 6.31 mostra a RNA que apresentou o $\text{EMR}_{\text{mín}}$ para a mesma saída; tem a camada intermediária similar a do modelo anterior (uma camada com quatro neurônios) diferenciando-se na camada de entrada, que tem três neurônios (umidade ótima e massa específica seca máxima na energia intermediária e valor de azul).

A Figura 6.32 apresenta os valores de massa específica seca máxima na energia normal previstos pelas RNAs apresentadas pelas Figuras 6.30 e 6.31 *versus* os valores reais (ensaios laboratoriais) para as vinte e cinco amostras usadas na fase de validação das redes. Nela podem ser visualizadas as retas obtidas a partir das regressões lineares realizadas.

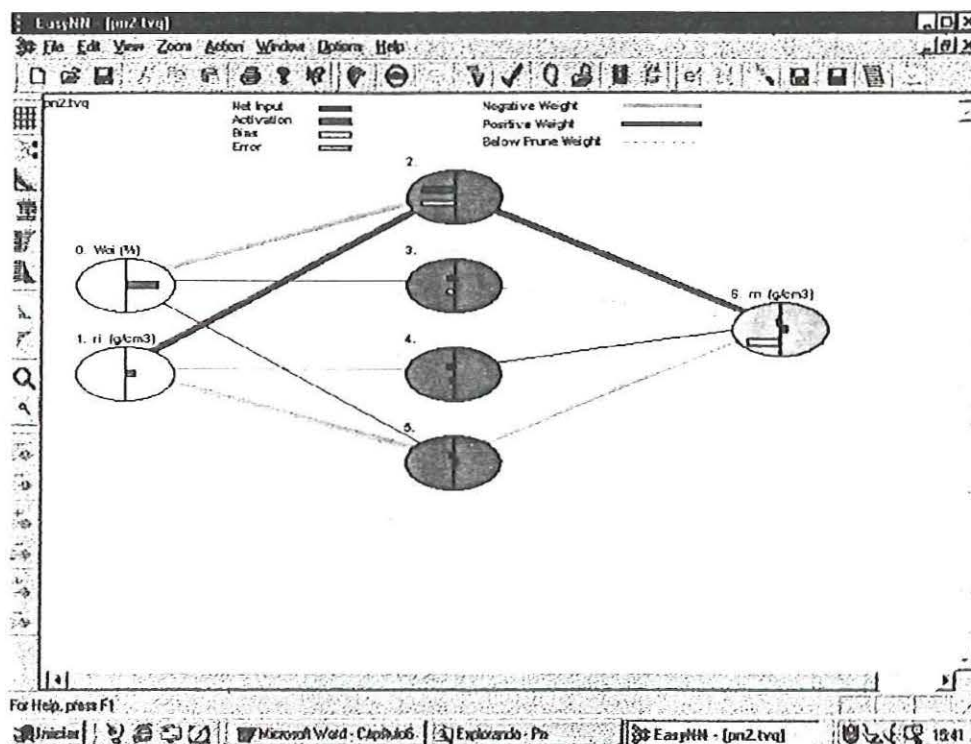


Figura 6.30 – A arquitetura da RNA que apresentou R^2_{\max} para a previsão da massa específica seca máxima na energia normal.

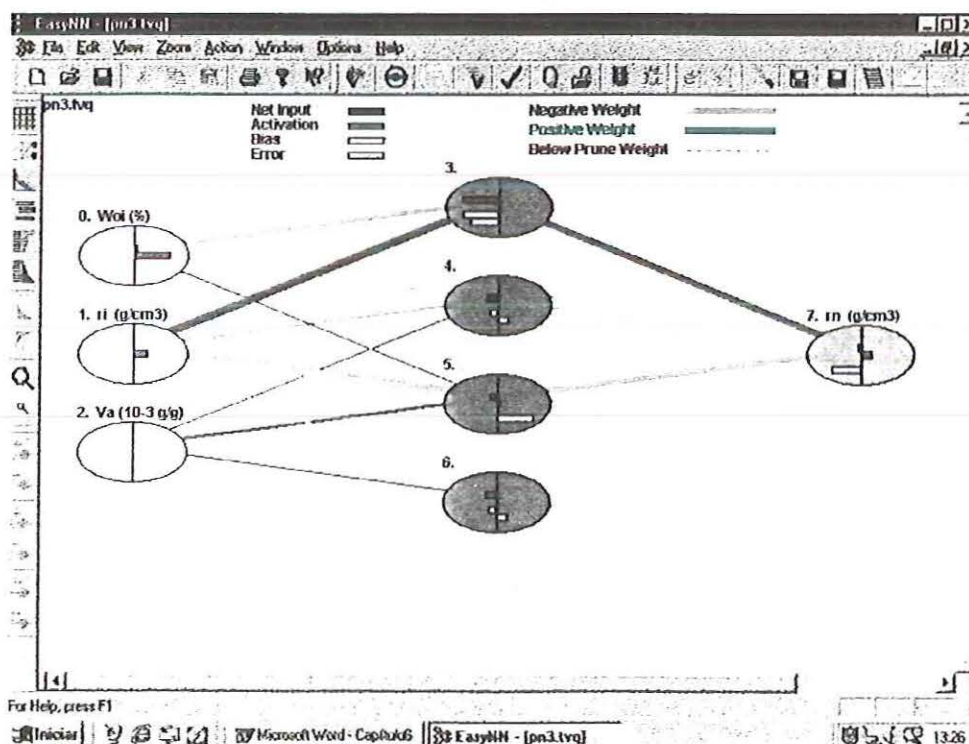


Figura 6.31 – A arquitetura da RNA que apresentou EMR_{\min} para a previsão da massa específica seca máxima na energia normal.




Figura 6.32 – Valores reais das massas específicas secas máximas na energia normal (ensaios) *versus* os previstos pelas RNAs, para os casos de $R^2_{máx}$ e de $EMR_{mín}$.

O valor do coeficiente de determinação máximo ($R^2_{máx}$) encontrado através de regressão linear para a massa específica seca máxima na energia normal foi igual a 0,86 e o erro médio relativo mínimo ($EMR_{mín}$) igual a 2,91%, com um respectivo coeficiente de determinação de 0,83.

As expressões 6.4 e 6.5 apresentam, respectivamente, as equações de regressão múltipla e os coeficientes de determinação (R^2) para a estimativa da massa específica seca máxima na energia normal, utilizando-se as mesmas variáveis usadas nas duas redes já apresentadas. Os modelos de regressão foram calculados a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes apresentadas anteriormente.

$$\rho_n = -0,007W_{oi} + 0,56\rho_i + 0,81 \quad (6.4)$$

$$R^2 = 0,74$$

$$p_n = -0,006W_{oi} + 0,56p_i + 1,89 \cdot 10^{-5} V_a + 0,81 \quad (6.5)$$

$$R^2 = 0,74$$

onde:

p_n : massa específica seca máxima na energia normal, em g/cm^3 ;

W_{oi} : umidade ótima na energia intermediária, em %;

p_i : massa específica seca máxima na energia intermediária, em g/cm^3 ;

V_a : valor de azul, em 10^{-3} g/g .

6.7.2.2. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA INTERMEDIÁRIA

A arquitetura que apresentou o maior coeficiente de determinação ($R^2_{\text{máx}}$) é mostrada na Figura 6.33. Ela tem como camada de saída a massa específica seca máxima na energia intermediária e é composta de uma camada de entrada com seis neurônios (umidade ótima e massa específica seca máxima na energia normal, valor de azul e frações do solo passadas nas peneiras de aberturas nominais de 0,42 mm, 0,074 mm e 0,005 mm) e uma camada intermediária com oito neurônios. A RNA que apresentou o EMR_{min} para a mesma saída, conforme apresenta a Figura 6.34, tem quatro neurônios na camada intermediária e três neurônios na camada de entrada (umidade ótima e massa específica seca máxima na energia normal e valor de azul).

A Figura 6.35 apresenta os valores de massa específica seca máxima na energia intermediária previstos pelas RNAs das Figuras 6.33 e 6.34 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação das redes. Nela também podem ser visualizadas as retas obtidas a partir de regressões lineares realizadas com esses resultados.

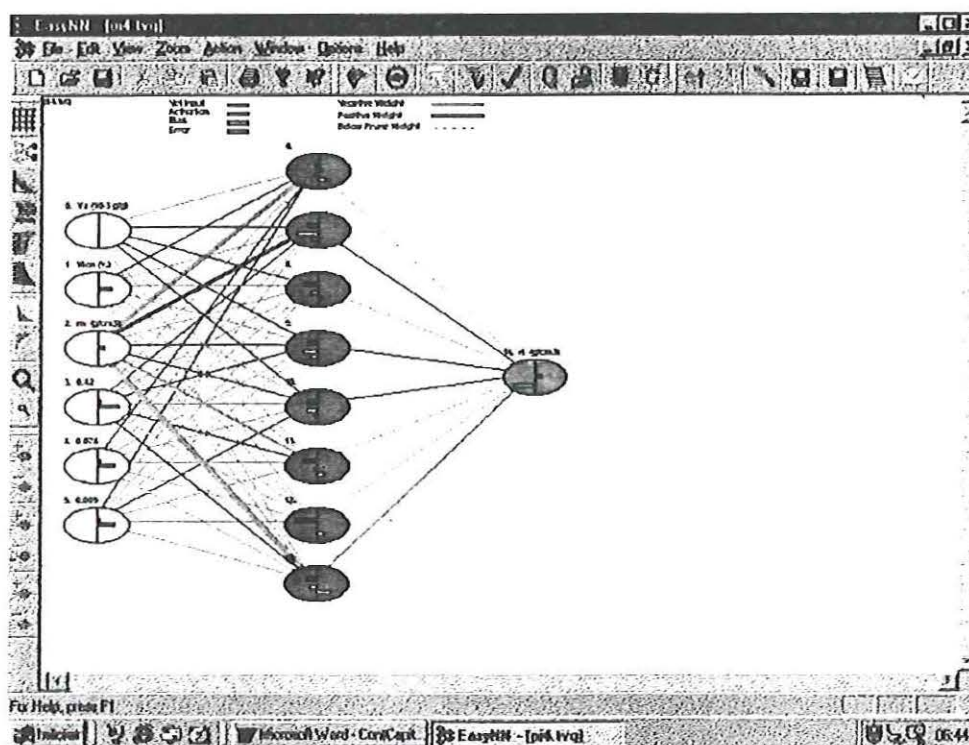


Figura 6.33 – A arquitetura da RNA que apresentou R^2_{\max} para a previsão da massa específica seca máxima na energia intermediária.

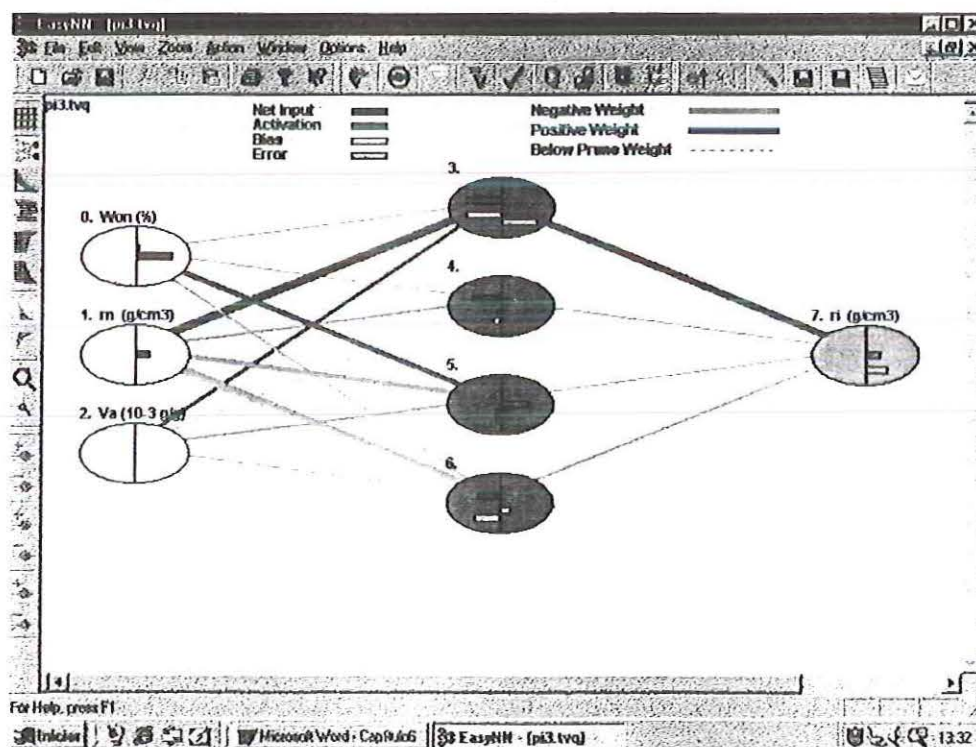


Figura 6.34 – A arquitetura da RNA que apresentou EMR_{\min} para a previsão da massa específica seca máxima na energia intermediária

O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado através de regressão linear para a massa específica seca máxima na energia intermediária foi 0,70 e o erro médio relativo mínimo ($\text{EMR}_{\text{mín}}$) igual a 4,87% apresentando, nesse caso, um coeficiente de determinação igual a 0,68.




Figura 6.35 – Valores reais das massas específicas secas máximas na energia intermediária (ensaios) *versus* os previstos pelas RNAs, para os casos de $R^2_{\text{máx}}$ e de $\text{EMR}_{\text{mín}}$.

As expressões 6.6 e 6.7 apresentam, respectivamente, as equações de regressão múltipla e os respectivos coeficientes de determinação (R^2) para previsão da massa específica seca máxima na energia intermediária utilizando-se os mesmos parâmetros de entrada usados nas redes apresentadas anteriormente. Os modelos de regressão foram determinados a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.

$$\rho_i = + 0,001W_{on} + 0,95p_n - 0,02V_a - 0,008(\#0,42) - 1,3 \cdot 10^{-4}(\#0,074) + 0,001(\#0,005) + 0,92 \quad (6.6)$$

$$R^2 = 0,71$$

$$\rho_i = 0,004W_{on} + 0,99\rho_n - 0,02V_a + 0,10 \quad (6.7)$$

$$R^2 = 0,69$$

onde:

ρ_i : massa específica seca máxima na energia intermediária, em g/cm^3 ;

W_{on} : umidade ótima na energia normal, em %;

ρ_n : massa específica seca máxima na energia normal, em g/cm^3 ;

V_a : valor de azul, em $10^{-3} g/g$;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.2.3. COMENTÁRIOS

Apesar dos resultados para a previsão da massa específica seca máxima na energia normal e intermediária serem muito bons, não foram tão bons quanto os obtidos para umidade ótima nas mesmas energias, para os casos dos coeficientes de determinação máximos ($R^2_{máx}$). Já para os erros médios mínimos (EMR_{min}) os resultados foram melhores que os obtidos para as umidades ótimas.

Os modelos de RNAs que apresentaram os erros médios mínimos (EMR_{min}) para massas específicas secas máximas nas energias normal e intermediária têm as mesmas arquiteturas (3-4-1) e as mesmas variáveis de entrada (umidade ótima, massa específica seca máxima e o valor de azul), conforme mostram as Figuras 6.31 e 6.34.

Já as arquiteturas das redes para os casos dos coeficientes de determinação máximos ($R^2_{máx}$) para as massas específicas secas máximas nas energias normal e intermediária (Figuras 6.30 e 6.33) apresentaram diferentes camadas de entrada. Para a energia normal o $R^2_{máx}$ foi maior que o da outra energia.

Os modelos de regressão múltipla para massa específica seca máxima na energia normal apresentaram coeficientes de determinação (R^2) inferiores aos dos modelos

das RNAs para as mesmas variáveis (expressão 6.4 e 6.5). Para a energia intermediária (expressão 6.6 e 6.7), os coeficientes foram similares para os dois tipos de modelos de previsão implementados (regressão e RNA), quando utiliza-se os mesmos parâmetros de entrada.

6.7.3. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA

6.7.3.1. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL

A Figura 6.36 apresenta a arquitetura da RNA que apresentou o $R^2_{\text{máx}}$ tendo como camada de saída o mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal e composta de uma camada de entrada com dois neurônios (mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária e o valor de azul) e duas camadas intermediárias (a 1ª com onze e a 2ª com sete neurônios). A Figura 6.37 mostra a RNA que apresentou o EMR_{min} para a mesma saída, com duas camadas intermediárias (a 1ª com onze e a 2ª com cinco neurônios) e a camada de entrada com quatro neurônios (mini-CBR na umidade de moldagem na energia intermediária e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm).

A Figura 6.38 apresenta os valores de mini-CBR na umidade de moldagem na energia normal previstos pelas RNAs das Figuras 6.36 e 6.37 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação da rede. Nela podem ser visualizadas as retas obtidas a partir de regressões lineares realizadas com esses resultados.

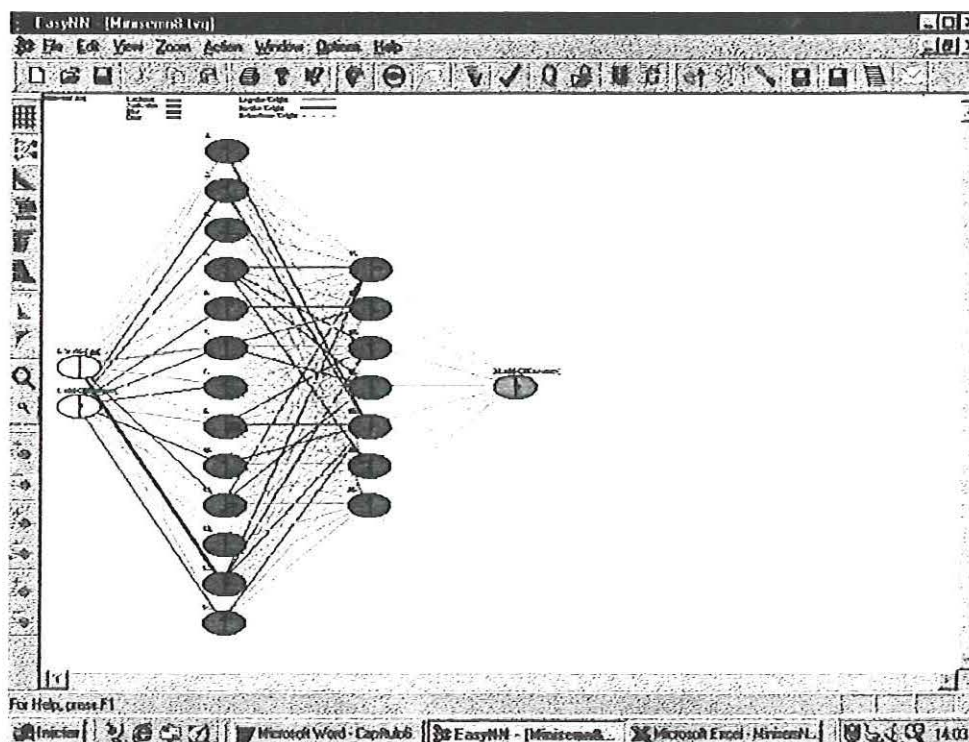


Figura 6.36 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão de mini-CBR na unidade de moldagem obtido na unidade ótima na energia normal.

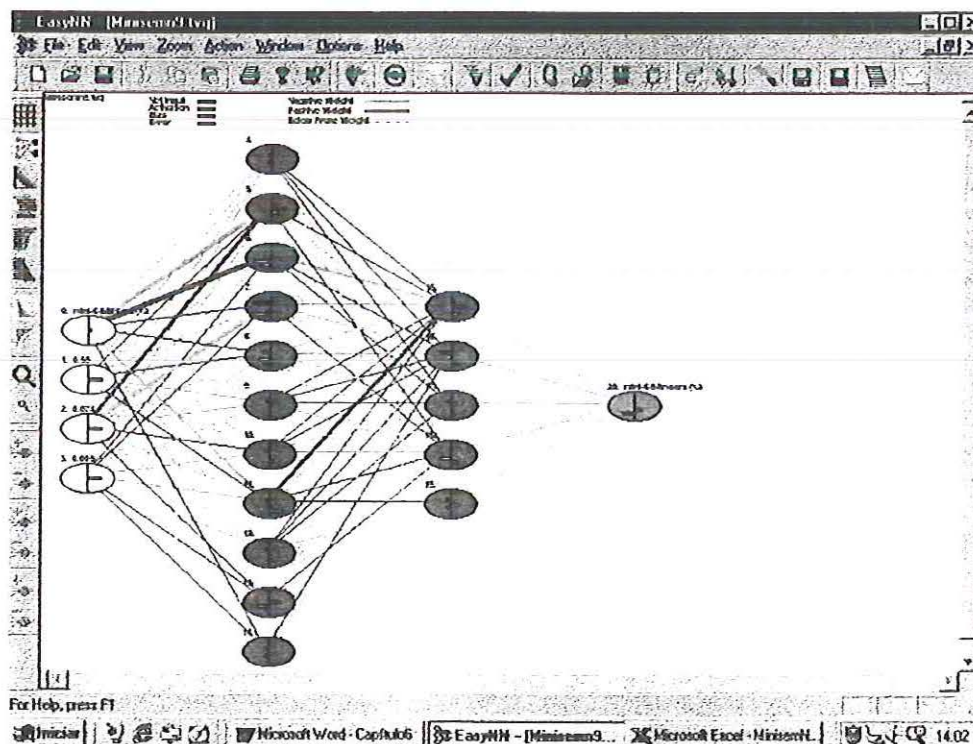


Figura 6.37 – A arquitetura da RNA que apresentou EMR_{min} para a previsão do mini-CBR na unidade de moldagem obtido na unidade ótima na energia normal.

O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado pela regressão linear para o mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal é igual a 0,45 e o erro médio relativo mínimo ($\text{EMR}_{\text{mín}}$) de 30,10%, com um coeficiente de determinação igual a 0,33.

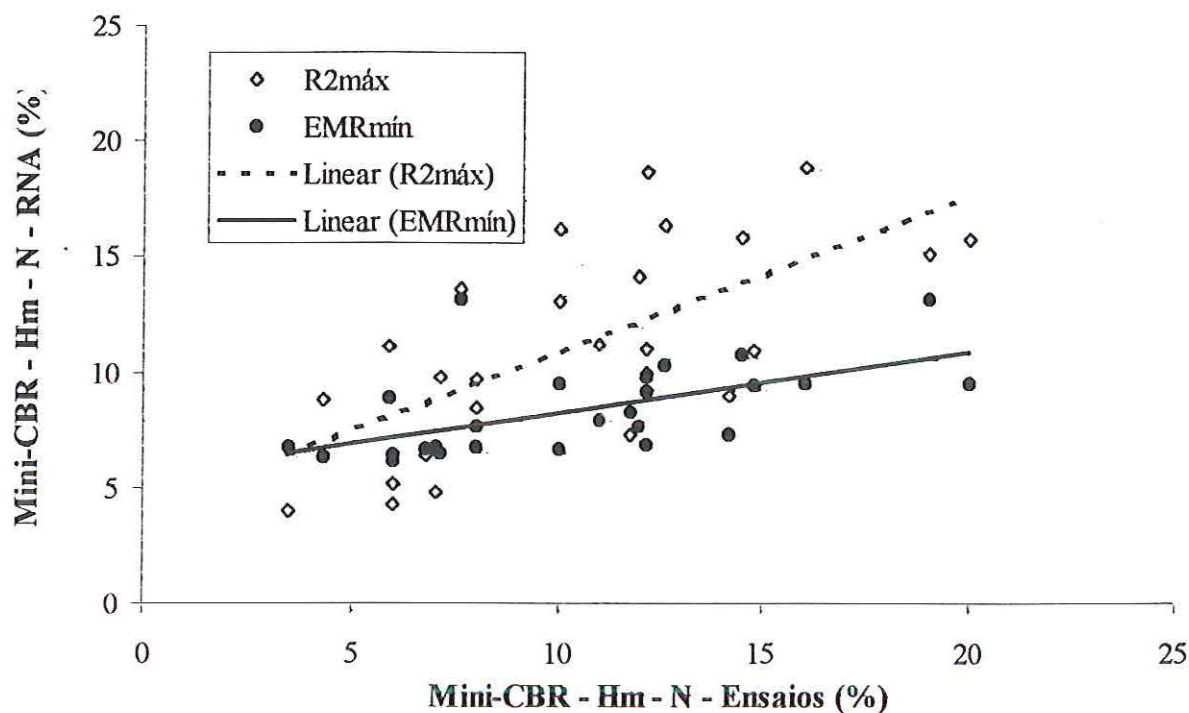


Figura 6.38 – Valores reais dos mini-CBRs na umidade de moldagem obtidos na umidade ótima na energia normal (ensaios) *versus* os previstos pelas RNAs, para os casos de $R^2_{\text{máx}}$ e de $\text{EMR}_{\text{mín}}$.

As expressões 6.8 e 6.9 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para previsão do mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal com os mesmos parâmetros utilizados nos modelos de redes usados para estimar esta propriedade. As regressões foram feitas a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.

$$\text{mini-CBR}(\text{Hm}_n) = 0,30\text{mini-CBR}(\text{Hm}_i) - 0,31V_a + 5,4 \quad (6.8)$$

$$R^2 = 0,51$$

$$\begin{aligned} \text{mini-CBR(Hmn)} = & 0,29\text{mini-CBR(Hmi)} - 0,14(\#0,42) - 0,11(\#0,074) + \\ & + 0,12(\#0,005) - 19,57 \end{aligned} \quad (6.9)$$

$$R^2 = 0,54$$

onde:

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(Hmi): mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, em %;

Va: valor de azul, em 10^{-3} g/g;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.3.2. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

A arquitetura da RNA para prever o mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, apresentada na Figura 6.39, foi a que obteve, simultaneamente, o $R^2_{\text{máx}}$ e o $\text{EMR}_{\text{mín}}$. Esta rede foi composta de uma camada de entrada com dois neurônios (mini-CBR na umidade de moldagem e mini-CBR após 24 h de imersão obtidos na umidade ótima na energia normal), três camadas intermediárias (a 1ª com dezenove, a 2ª com sete e a 3ª com seis neurônios) e a camada de saída com o mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária.

A Figura 6.40 apresenta os valores de mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária previstos pela RNA da Figura 6.39 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação da rede. Nela pode ser visualizada a reta obtida a partir de regressão linear realizada com esses resultados.

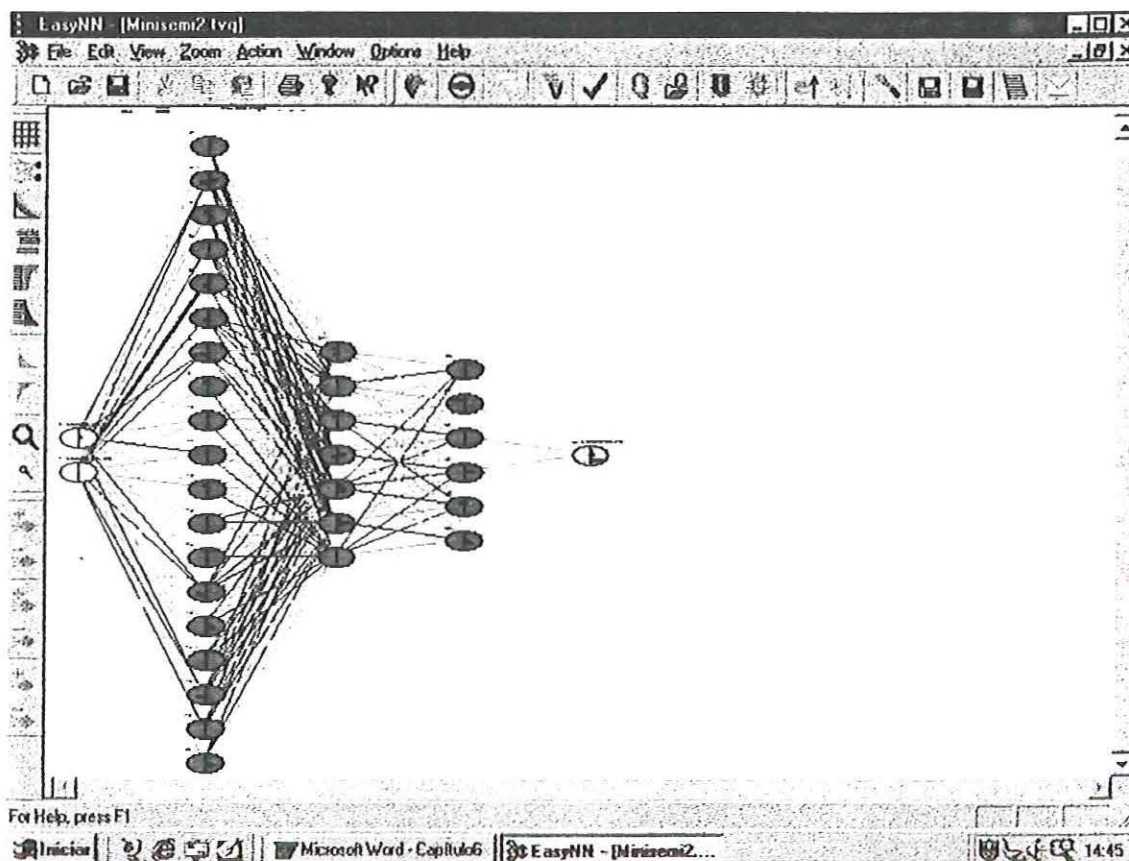


Figura 6.39 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ e $\text{EMR}_{\text{mín}}$ para a previsão do mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária.

O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado pela regressão linear para o mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária é igual a 0,25 e o erro médio relativo mínimo ($\text{EMR}_{\text{mín}}$) é igual a 40,41%, com um coeficiente de determinação de 0,25 nesse caso.

A expressão 6.10 apresenta a equação de regressão e o coeficiente de determinação (R^2) para previsão do mini-CBR na umidade de moldagem na energia intermediária com as mesmas variáveis utilizadas no modelo de RNA para prever esta propriedade. O modelo de regressão foi calculado a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.




Figura 6.40 – Valores reais dos mini-CBRs na umidade de moldagem obtidos na umidade ótima na energia intermediária (ensaios) *versus* os previstos pela RNA.

$$\text{mini-CBR(Hmi)} = 1,07\text{mini-CBR(Hmn)} + 1,02\text{mini-CBR(24hn)} + 5,58 \quad (6.10)$$

$$R^2 = 0,54$$

onde:

mini-CBR(Hmi): mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, em %;

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %.

6.7.3.3.COMENTÁRIOS

Os desempenhos das RNAs para as previsões dos mini-CBRs nas umidades de moldagem obtidos nas umidades ótimas nas energias normal e intermediária não foram muito bons, o que pode ser constatado, respectivamente, nas Figuras 6.38 e 6.40 e através dos valores dos coeficientes de determinação máximos (R^2_{\max}) e os

erros médios relativos mínimos (EMR_{\min}) encontrados nos processos de validação das redes.

Os resultados para os modelos de regressão múltipla do mini-CBR na umidade de moldagem obtido na umidade ótima nas energias normal (expressão 6.8 e 6.9) e intermediária (expressão 6.10), de um modo geral, foram melhores que os das RNAs para as mesmas variáveis estudadas. Vale salientar que os valores dos coeficientes de determinação obtidos para os modelos de regressão múltipla foram semelhantes para as duas energias.

6.7.4. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA

6.7.4.1. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL

A Figura 6.41 apresenta a arquitetura da RNA que, coincidentemente, apresentou o R^2_{\max} e EMR_{\min} para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal. Ela é composta de uma camada de entrada com quatro neurônios (mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm) e duas camadas intermediárias (a 1ª com onze e a 2ª com cinco neurônios).

A Figura 6.42 mostra os valores de mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal previstos pela RNA da Figura 6.41 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação da rede. Nela pode ser visualizada a reta obtida a partir de regressão linear realizada com os resultados.

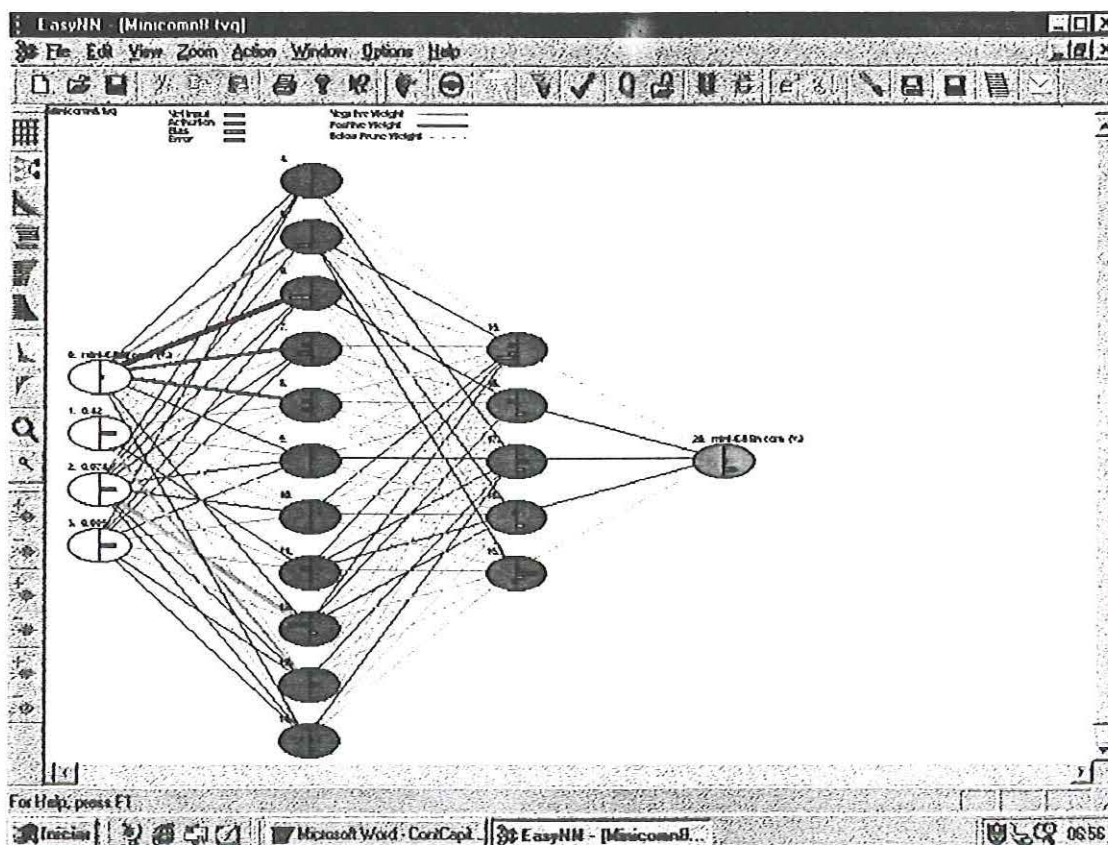


Figura 6.41 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ e $\text{EMR}_{\text{mín}}$ para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal.

O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado através de regressão linear para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal é igual a 0,34 e o erro médio relativo mínimo ($\text{EMR}_{\text{mín}}$) é igual a 38,94%.

A expressão 6.11 mostra a equação de regressão e o coeficiente de determinação (R^2) para previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal com as mesmas variáveis utilizadas no modelo de RNA para estimar esta propriedade. A regressão foi realizada utilizando-se o conjunto completo de dados (101 casos) usado nas fases de treinamento, teste e validação das redes.




Figura 6.42 – Valores reais dos mini-CBRs após 24 h de imersão obtidos na umidade ótima na energia normal (ensaaios) *versus* os previstos pela RNA.

$$\begin{aligned} \text{mini-CBR}(24\text{hn}) = & +0,29\text{mini-CBR}(24\text{hi}) - 0,06(\#0,42) - 0,08(\#0,074) + \\ & + 0,10(\#0,005) + 9,72 \end{aligned} \quad (6.11)$$

$$R^2 = 0,49$$

onde:

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %;

mini-CBR(24hi): mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, em %;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.4.2. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

A Figura 6.43 apresenta a arquitetura da RNA que apresentou o $R^2_{\text{máx}}$. Esta RNA é formada por uma camada de saída, representando o mini-CBR após 24 h de imersão

obtido na umidade ótima na energia intermediária, por uma camada de entrada com quatro neurônios (mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal e frações de solos passadas nas peneiras de abertura nominal 0,42 mm, 0,074 mm e 0,005 mm) e por duas camadas intermediárias (a 1ª com treze e a 2ª com seis neurônios). A Figura 6.44 mostra a RNA que apresentou o EMR_{\min} para a mesma saída. Ela tem o mesmo padrão de camadas intermediárias, da Figura 6.43, diferenciando-se na camada de entrada, que conta com seis neurônios (mini-CBR na umidade de moldagem obtido na umidade ótima e mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, valor de azul e frações de solos passadas nas peneiras de abertura nominal 0,42 mm, 0,074 mm e 0,005 mm).

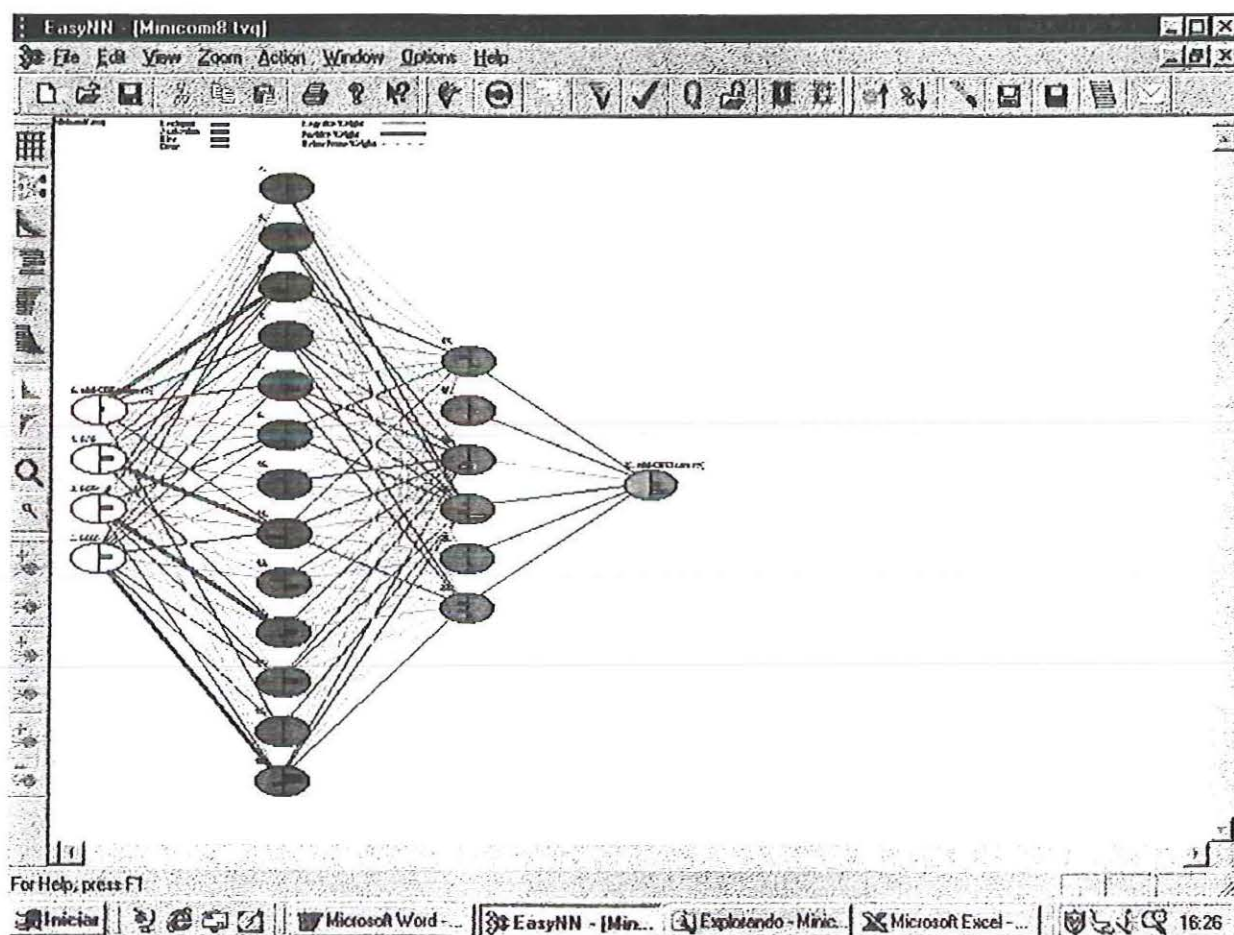


Figura 6.43 – A arquitetura da RNA que apresentou R^2_{\max} para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária.

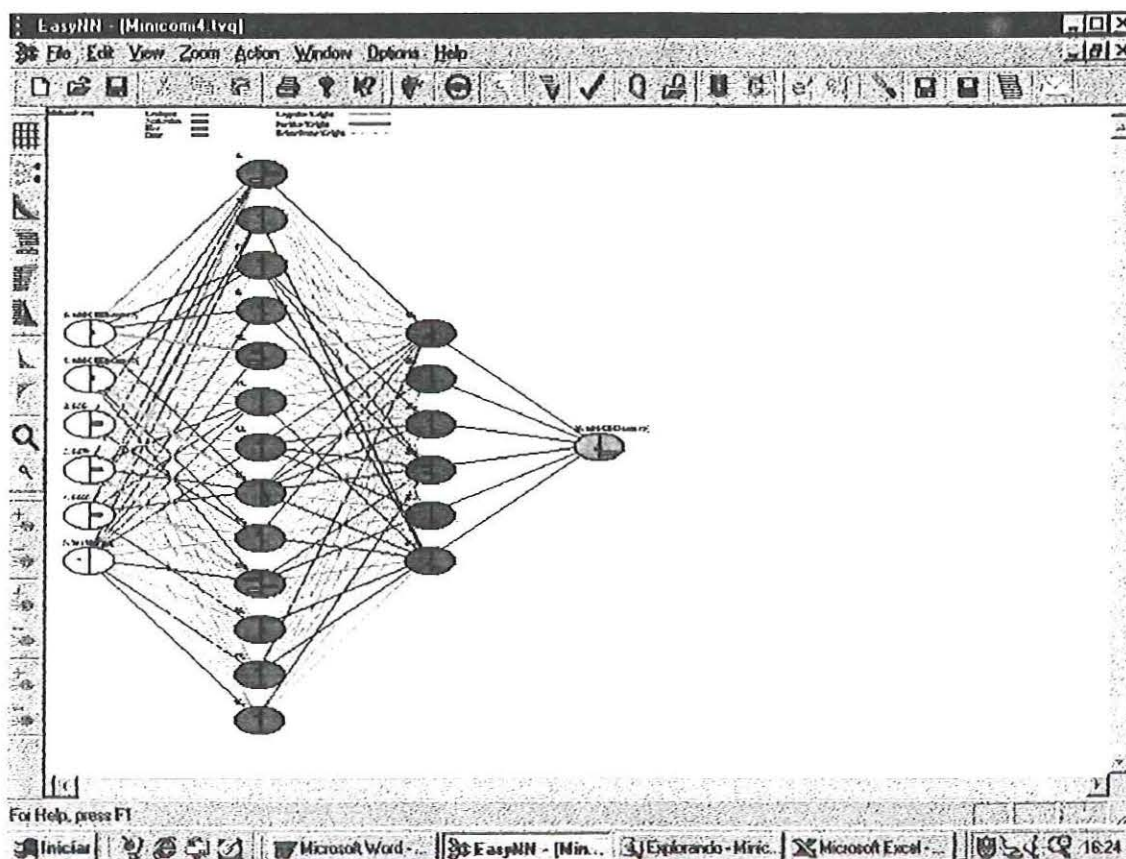


Figura 6.44 – A arquitetura da RNA que apresentou EMR_{\min} para a previsão de mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária.

A Figura 6.45 apresenta os valores de mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária previstos pelas RNAs das Figuras 6.43 e 6.44 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação das redes. Nela podem ser visualizadas as retas de regressão realizadas com esses resultados.

O valor do coeficiente de determinação máximo (R^2_{\max}) encontrado para o mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária é igual a 0,53 e o erro médio relativo mínimo (EMR_{\min}) igual a 48,81%, para um coeficiente de determinação igual a 0,20.




Figura 6.45 – Valores reais dos Mini-CBRs após 24 h de imersão obtidos na umidade ótima na energia intermediária (ensaios) *versus* os previstos pelas RNAs, para os casos de $R^2_{máx}$ e de $EMR_{mín}$.

As expressões 6.12 e 6.13 apresentam, respectivamente, as equações de regressão múltipla e os coeficientes de determinação (R^2) para previsão do mini-CBR após 24 h de imersão na energia intermediária com os mesmos parâmetros utilizados nos modelos de redes para estimar esta propriedade. Os modelos de regressão foram calculados a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.

$$\begin{aligned} \text{mini-CBR}(24hi) = & 1,34\text{mini-CBR}(24hn) - 0,59(\#0,42) + 0,02(\#0,074) + \\ & + 0,05(\#0,005) + 61,69 \end{aligned} \quad (6.12)$$

$$R^2 = 0,50$$

$$\begin{aligned} \text{mini-CBR}(24hi) = & 0,40\text{mini-CBR}(Hmn) + 0,84\text{mini-CBR}(24hn) - 1,07Va - \\ & - 0,57(\#0,42) + 0,08(\#0,074) + 0,06(\#0,005) + 58,02 \end{aligned} \quad (6.13)$$

$$R^2 = 0,53$$

onde:

mini-CBR(24hi): mini-CBR CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, em %;

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(24hn): mini-CBR após 24h de imersão obtido na umidade ótima na energia normal, em %;

Va: valor de azul, em 10^{-3} g/g;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.4.3.COMENTÁRIOS

Os modelos de regressão múltipla para mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal apresentaram coeficientes de determinação (R^2) superiores aos dos modelos das RNAs para as mesmas variáveis (expressão 6.12 e 6.13).

O desempenho da RNA para mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, para $R^2_{\text{máx}}$ (igual a 0,53), mostrou um comportamento semelhante quando comparado com o modelo de regressão múltipla ($R^2 = 0,50$).

O desempenho da RNA para a previsão do mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária ($R^2_{\text{máx}} = 0,53$) foi mais satisfatório do que para a energia normal ($R^2_{\text{máx}} = 0,34$), mesmo ressaltando-se que ambos os modelos tiveram as mesmas variáveis de entrada (mini-CBR após 24 h de imersão trocada para cada modelo e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm (%)).

6.7.5. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA

6.7.5.1. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL

A arquitetura de rede que apresentou o coeficiente de determinação máximo ($R^2_{\text{máx}}$) para a previsão da expansão obtida na umidade ótima na energia normal tem uma camada de entrada com quatro neurônios (valor de azul e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm) e duas camadas intermediárias (a 1ª com treze e a 2ª com seis neurônios), conforme apresenta a Figura 6.46. Cabe ressaltar que não foi possível calcular o erro médio relativo mínimo ($\text{EMR}_{\text{mín}}$) para esta propriedade, pois houve a ocorrência de expansões na energia normal valores iguais a zero.

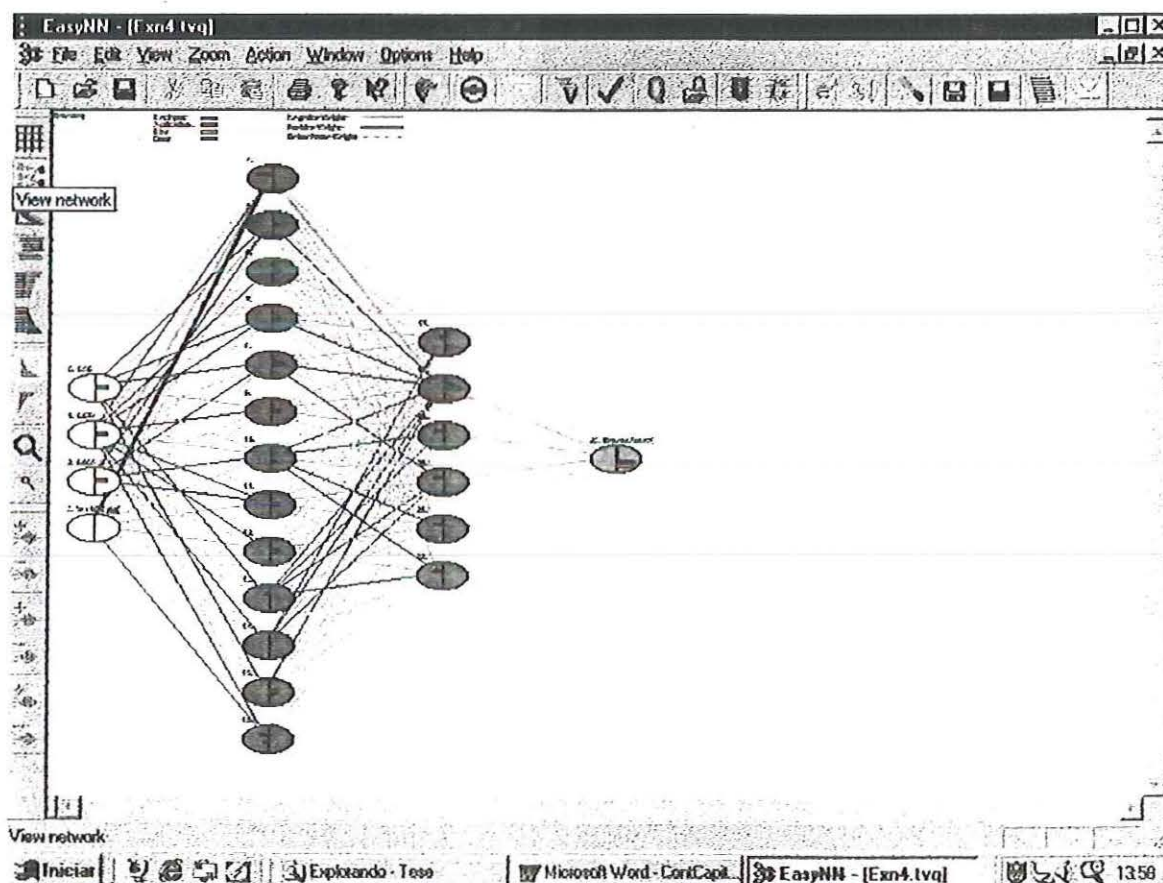


Figura 6.46 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da expansão obtida na umidade ótima na energia normal.

A Figura 6.47 apresenta os valores de expansão obtida na umidade ótima na energia normal previstos pela RNA da Figura 6.46 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação da rede. Nela pode ser visualizada a reta de regressão linear obtida com esses dados.

O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado através da regressão linear foi 0,53.




Figura 6.47 – Valores reais das expansões obtidos na umidade ótima na energia normal (ensaios) *versus* os previstos pela RNA.

A expressão 6.14 mostra a equação de regressão múltipla e o coeficiente de determinação (R^2) para previsão da expansão obtida na umidade ótima na energia normal com as mesmas variáveis utilizadas no modelo de RNA. O modelo de regressão foi determinado utilizando-se o conjunto completo de dados (101 casos) usado nas fases de treinamento, teste e validação das redes.

$$E_n = 0,06V_a - 0,007(\#0,42) + 0,003(\#0,074) - 0,005(\#0,005) + 0,74 \quad (6.14)$$

$$R^2 = 0,20$$

onde:

En: expansão obtida na umidade ótima na energia normal (%)

Va: valor de azul, em 10^{-3} g/g;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.5.2. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

A Figura 6.48 mostra a arquitetura da RNA que obteve o coeficiente de determinação máximo ($R^2_{\text{máx}}$) para a previsão da expansão na energia intermediária e que tem uma camada de entrada com quatro neurônios (expansão na energia normal e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm) e duas camadas intermediárias (a 1ª com onze e a 2ª com seis neurônios) e por fim a camada de saída para a expansão na energia intermediária. Cabe ressaltar, também, que não foi possível calcular o erro médio relativo mínimo ($EMR_{\text{mín}}$) para esta propriedade, pois a expansão na energia intermediária também apresenta alguns valores iguais a zero.

A Figura 6.49 apresenta os valores de expansão obtida na umidade ótima na energia intermediária previstos pela RNA da Figura 6.48 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação da rede. Nela pode ser visualizada a reta obtida a partir de regressão linear realizada com esses resultados. O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado pela regressão linear para a expansão na energia intermediária é igual a 0,41.

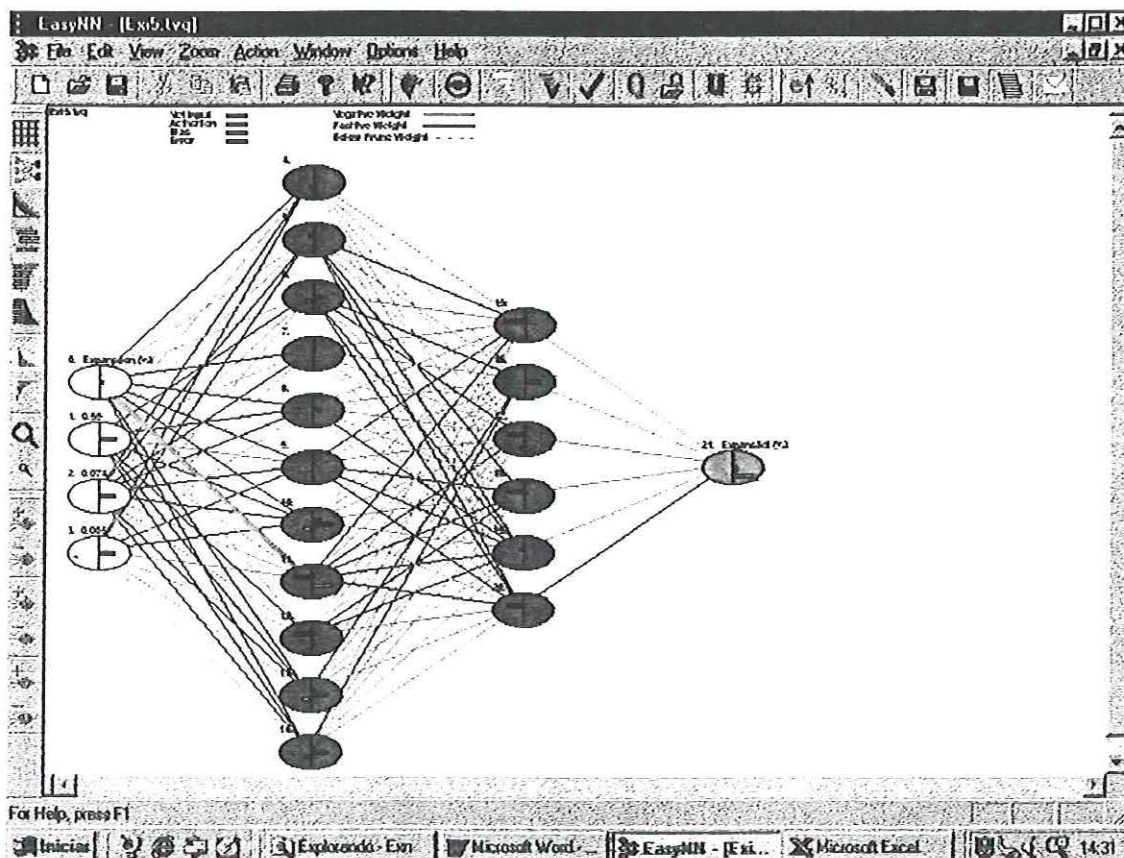


Figura 6.48 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ para a previsão da expansão obtida na umidade ótima na energia intermediária.




Figura 6.49 – Valores reais das expansões obtidas na umidade ótima na energia intermediária (ensaios) *versus* os previstos pela RNA.

A expressão 6.15 apresenta a equação de regressão múltipla e o coeficiente de determinação (R^2) para previsão da expansão obtida na umidade ótima na energia intermediária a partir das mesmas variáveis utilizadas no modelo de RNA para a previsão desta propriedade. O modelo de regressão foi calculado a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação da rede.

$$E_i = 0,43E_n - 0,009(\#0,42) + 0,002(\#0,074) + 0,0006(\#0,005) + 0,86 \quad (6.15)$$

$$R^2 = 0,34$$

onde:

E_i : expansão obtida na umidade ótima na energia intermediária, em (%);

E_n : expansão obtida na umidade ótima na energia normal, em (%);

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.5.3. COMENTÁRIOS

Para o estudo da expansão obtida na umidade ótima não foi possível calcular o erro médio relativo mínimo (EMR_{\min}), pois esta propriedade, tanto na energia normal e como na intermediária, apresenta alguns valores iguais a zero. Em relação ao coeficientes de determinação máximos (R^2_{\max}) para as RNAs, obteve-se valor maior para o da energia normal em relação ao da energia intermediária. Os dois modelos foram desenvolvidos com duas camadas intermediárias e com as camadas de entrada compostas de quatro variáveis, sendo três (frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm (%)) iguais nos dois modelos e a quarta o valor de azul, para o caso da energia normal, e a expansão na energia normal, para o caso da energia intermediária.

Os desempenhos dos modelos de regressão múltipla das expansões obtidas na umidade ótima na energias normal (expressão 6.14) e intermediária (expressão 6.15) foram menos favoráveis que os das RNAs, quando utilizadas as mesmas variáveis de entrada.

6.7.6. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA

6.7.6.1. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL

A Figura 6.50 mostra a arquitetura da RNA que apresentou o R^2_{\max} para a camada de saída igual à contração obtida na umidade ótima na energia normal. Essa RNA tem a camada de entrada com cinco neurônios (contração obtida na umidade ótima na energia intermediária, valor de azul e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm) e duas camadas intermediárias (a 1ª com doze e a 2ª com seis neurônios). A Figura 6.51 mostra a RNA que apresentou o EMR_{\min} que, por sua vez, tem duas camadas intermediárias (a 1ª com quatorze e a 2ª com cinco neurônios) e a camada de entrada contém dois neurônios (contração obtida na umidade ótima na energia intermediária e valor de azul).

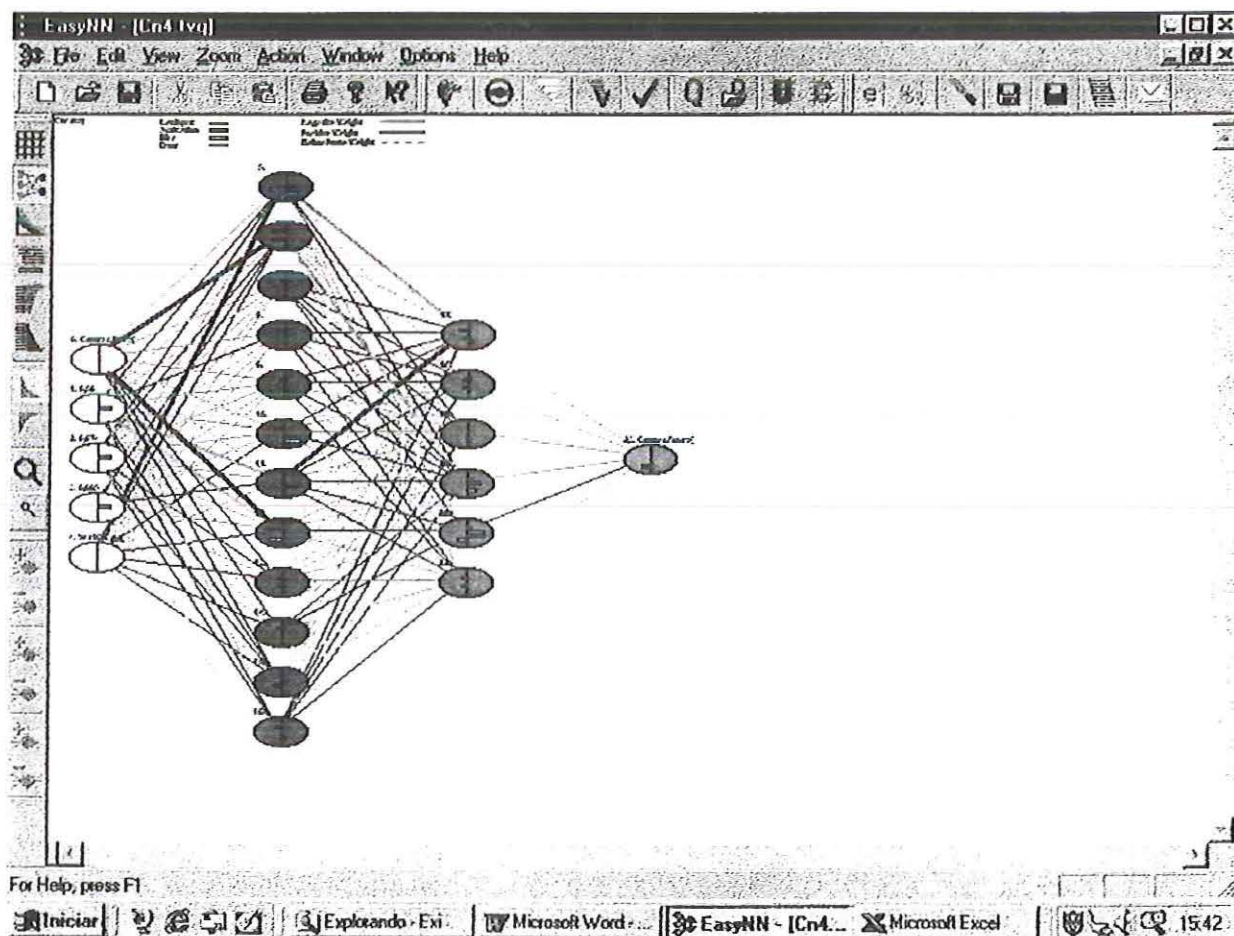


Figura 6.50 – A arquitetura da RNA que apresentou R^2_{\max} para a previsão da contração obtida na umidade ótima na energia normal.

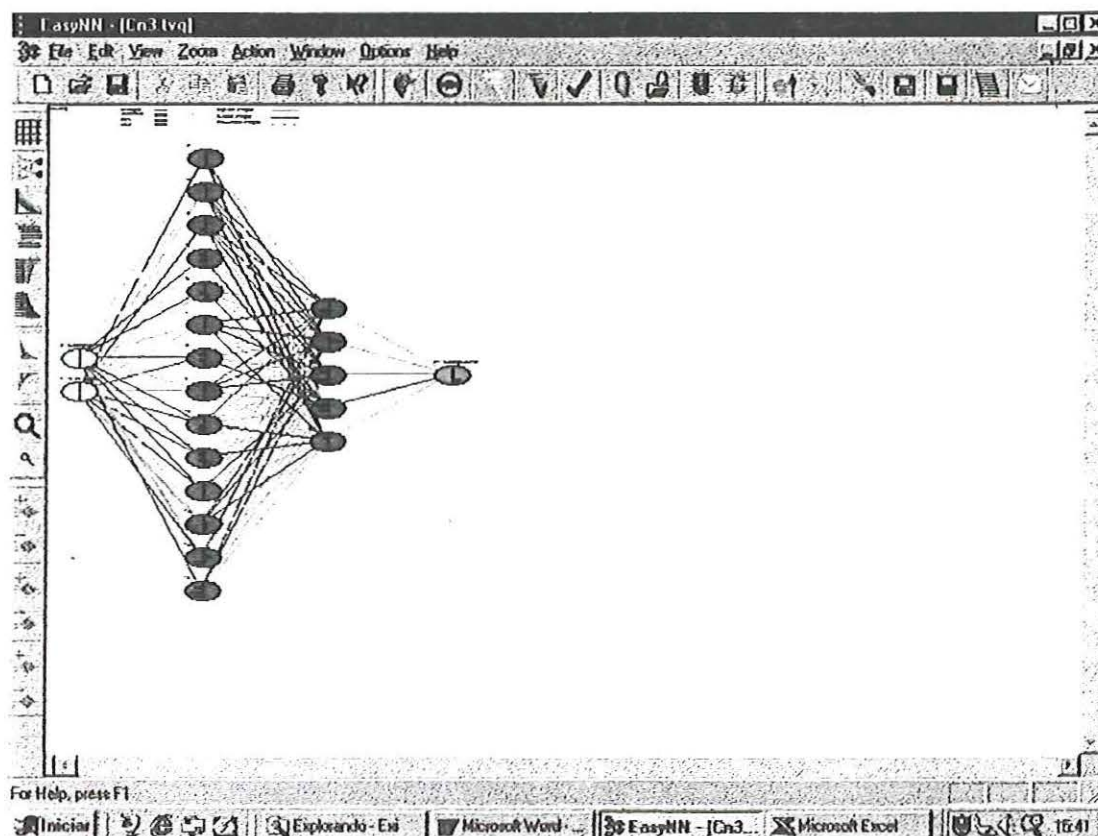


Figura 6.51 – A arquitetura da RNA que apresentou EMR_{\min} para a previsão da contração obtida na umidade ótima na energia normal.

A Figura 6.52 apresenta os valores das contrações obtidas na umidade ótima na energia normal previstos pelas RNAs das Figuras 6.50 e 6.51 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação das redes. Nela podem ser visualizadas as retas obtidas a partir de regressões lineares realizadas com esses resultados.

O valor do coeficiente de determinação máximo (R^2_{\max}) encontrado pela regressão linear para contração obtida na umidade ótima na energia normal é igual a 0,70 e o erro médio relativo mínimo (EMR_{\min}) é igual a 43,80%, com um coeficiente de determinação correspondente a essa rede igual a 0,63.




Figura 6.52 – Valores reais das contrações obtidos na umidade ótima na energia normal (ensaios) *versus* os previstos pelas RNAs, para os casos de $R^2_{máx}$ e de $EMR_{mín}$.

As expressões 6.16 e 6.17 apresentam as equações de regressão múltipla e os coeficientes de determinação (R^2) para previsão da contração obtida na umidade ótima na energia normal utilizando-se mesmos parâmetros usados nos modelos de redes ($R^2_{máx}$ e $EMR_{mín}$) feitos para estimar esta propriedade. Os modelos de regressão foram calculados a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.

$$C_n = 0,44C_i + 0,13V_a + 0,007(\#0,42) + 0,0005(\#0,074) + 0,004(\#0,005) - 0,59 \quad (6.16)$$

$$R^2 = 0,73$$

$$C_n = 0,49C_i + 0,16V_a + 0,08 \quad (6.17)$$

$$R^2 = 0,72$$

onde:

Cn: Contração obtida na umidade ótima na energia normal, em %;

Ci: contração obtida na umidade ótima na energia normal, em %;

Va: valor de azul, em 10^{-3} g/g;

(#0,42), (#0,074), (#0,005): frações passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.6.2. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

A arquitetura apresentada pela Figura 6.53 apresentou tanto o máximo coeficiente de determinação ($R^2_{\text{máx}}$) como o mínimo erro médio relativo (EMR_{min}), tendo como camada de saída a contração obtida na umidade ótima na energia intermediária, como camada de entrada quatro neurônios (contração na energia normal e frações de solos passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm) e duas camadas intermediárias (a 1ª com onze e a 2ª com cinco neurônios).

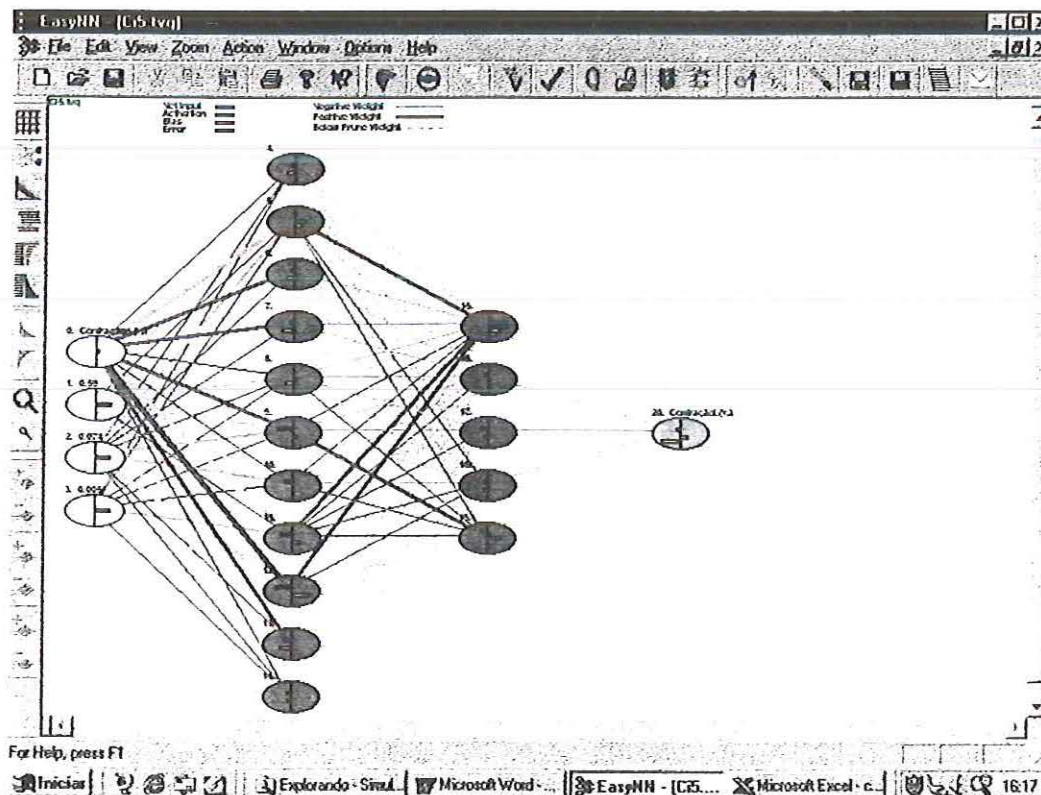


Figura 6.53 – A arquitetura da RNA que apresentou $R^2_{\text{máx}}$ e EMR_{min} para a previsão da contração obtida na umidade ótima na energia intermediária.

A Figura 6.54 mostra os valores de contração obtida na umidade ótima na energia intermediária previstos pela RNA da Figura 6.53 *versus* os valores reais (ensaios laboratoriais) para os vinte e cinco casos usados na fase de validação da rede. Nela pode ser visualizada a reta obtida a partir de regressão linear realizada com esses resultados.

O valor do coeficiente de determinação máximo ($R^2_{\text{máx}}$) encontrado pela regressão linear para a contração obtida na umidade ótima na energia intermediária é igual a 0,85 e o erro médio relativo mínimo ($\text{EMR}_{\text{mín}}$) é igual a 54,60%.




Figura 6.54 – Valores reais das contrações obtidos na umidade ótima na energia intermediária (ensaios) *versus* os previstos pela RNA.

A expressão 6.18 apresenta a equação de regressão múltipla e o coeficiente de determinação (R^2) para previsão da contração obtida na umidade ótima na energia intermediária utilizando as mesmas variáveis do modelo de RNA usado para a previsão desta propriedade. O modelo de regressão foi calculado a partir do conjunto completo de dados (101 casos) utilizado nas fases de treinamento, teste e validação das redes.

$$C_i = 0,60C_n - 0,007(\#0,42) + 0,006(\#0,074) + 0,0005(\#0,005) + 0,55 \quad (6.18)$$

$$R^2 = 0,66$$

onde:

C_i : contração obtida na umidade ótima na energia intermediária, em (%);

C_n : contração obtida na umidade ótima na energia normal, em (%);

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074 mm e 0,005 mm.

6.7.6.3.COMENTÁRIOS

A simulação da rede para previsão da contração apresentaram resultados muitos bons, considerando-se os valores dos coeficientes de determinação ($R^2_{máx}$) na energia normal (igual a 0,70) e intermediária (igual a 0,85), embora os erros médios relativos mínimos (EMR_{min}) não tenham tido a mesma qualidade.

Os modelos de regressão para as contrações obtidas nas umidades ótimas nas energias normal (expressão 6.16 e 6.17) e intermediária (expressão 6.18) confirmam os resultados das RNAs, pois também apresentaram bons desempenhos usando as mesmas variáveis de entrada.

CAPÍTULO 7: CONSIDERAÇÕES FINAIS E CONCLUSÕES

7.1. INTRODUÇÃO

Este estudo demonstrou que há possibilidade de se fazer previsão de algumas propriedades de solos pertencentes à região de São Carlos (SP), utilizando-se as Redes Neurais Artificiais. Os resultados encontrados apresentaram bom desempenho quando comparados aos valores reais das propriedades os valores obtidos dos ensaios laboratoriais.

Os resultados de RNAs para as previsões de oito propriedades, a saber: umidade ótima, massa específica seca máxima e contração nas energias normal e intermediária, mini-CBR após 24 h de imersão obtido umidade ótima na energia intermediária, expansão obtida umidade ótima na energia normal apresentaram coeficientes de determinação máximos ($R^2_{máx}$) maiores que 0,5. Já para as outras quatro propriedades: mini-CBR na umidade de moldagem obtido na umidade ótima nas energias normal e intermediária, mini-CBR após 24 h de imersão obtido umidade ótima na energia normal e a expansão obtida umidade ótima na energia intermediária obtiveram coeficientes de determinação máximos menores que 0,5.

Entretanto não se pode afirmar que essas são as melhores arquiteturas, para previsão com essa base de dados, mas são os melhores resultados que foram obtidos nesse estudo.

7.2. RELAÇÕES ENTRE AS PROPRIEDADES TECNOLÓGICAS DOS SOLOS ESTUDADOS E O VALOR DE AZUL (VA)

Dos doze modelos de regressão linear simples testados, quatro, umidades ótimas e contrações obtidas nas umidades ótimas das energias normal e intermediária *versus* o V_a apresentaram bons resultados, com respectivamente, coeficientes de

determinação (R^2) iguais a 0,67, 0,63, 0,59 e 0,50. Há uma tendência de os valores da umidade ótima e da contração obtida na umidade ótima nas energias normal e intermediária crescerem com o aumento do valor de azul.

Os outros oito modelos de regressão linear simples entre as propriedades tecnológicas dos solos e o Va não apresentaram resultados satisfatórios. Essas propriedades são: massa específica seca máxima, mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR após 24 h de imersão obtido na umidade ótima e expansão obtido na umidade ótima nas energias normal e intermediária.

7.3. RELAÇÕES ENTRE AS PROPRIEDADES TECNOLÓGICAS DOS SOLOS ESTUDADOS

As regressões lineares resultaram em coeficientes de determinação (R^2) iguais a 0,97 para umidade ótima na energia normal *versus* umidade ótima na energia intermediária, a 0,68 para massa específica seca máxima na energia normal *versus* massa específica seca máxima na energia intermediária, a 0,51 para mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal *versus* mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, a 0,46 para mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal *versus* mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, a 0,26 para expansão obtida na umidade ótima na energia normal *versus* expansão obtida na umidade ótima na energia intermediária e a 0,63 para contração obtida na umidade ótima na energia normal *versus* contração obtida na umidade ótima na energia intermediária.

Com esses resultados, verifica-se que existem boas correlações entre três das seis propriedades, a saber: a umidade ótima, a massa específica seca máxima e a contração para as energias normal e intermediária.

7.4. REDES NEURAIAS ARTIFICIAIS (RNAs)

Os resultados dos procedimentos para as previsões das umidades ótimas na energia normal e intermediária apresentaram resultados excelentes. Os coeficientes de determinação máximo ($R^2_{m\acute{a}x}$), as retas de regressão e os erros médios mínimos (EMR_{min}) para essas RNAs (Figuras 6.26 e 6.29) comprovam os seus desempenhos.

Para o estudo da previsão da massa específica seca máxima nas energias normal e intermediária os resultados foram menos favoráveis que os obtidos para umidades ótimas nas mesmas energias, para os casos dos coeficientes de determinação máximos ($R^2_{m\acute{a}x}$). Já para os erros médios mínimos (EMR_{min}), os resultados foram melhores, o que pode ser constatado nas Figuras 6.32 ($R^2_{m\acute{a}x}$ e EMR_{min} para a energia normal) e 6.35 ($R^2_{m\acute{a}x}$ e EMR_{min} para a energia intermediária).

A simulação da rede para a contração, considerando-se os valores dos coeficientes de determinação ($R^2_{m\acute{a}x}$) nas energias normal (Figura 6.52) e intermediária (Figura 6.54) encontrados no processo de validação das redes apresentaram resultados muito bons, embora os erros médios relativos mínimos (EMR_{min}) não tenham tido a mesma qualidade.

Os desempenhos das RNAs para a previsão das seguintes propriedades: mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão e expansão obtidas na umidade ótima nas energias normal e intermediária não foram bons, o que pode ser constatado através dos valores dos coeficientes de determinação ($R^2_{m\acute{a}x}$) e os erros médios relativos mínimos (EMR_{min}) encontrados no processo de validação da rede para esta propriedade, respectivamente, pelas Figuras 6.38 e 6.40; Figuras 6.42 e 6.45; Figuras 6.47 e 6.49,.

Para a previsão de propriedades geotécnicas dos solos, os desempenhos das redes tiveram comportamentos favoráveis para umidade ótima, massa específica seca máxima e contração nas energias normal e intermediária, apresentando para essas propriedades coeficientes de determinação ($R^2_{m\acute{a}x}$) entre 0,70 a 0,95 e erros médios relativos mínimos (EMR_{min}) entre 2,91 a 9,88; excetuando a contração. Contudo, os

desempenhos das RNAs para mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão e expansão obtidas na umidade ótima nas energias normal e intermediária tiveram comportamentos menos favoráveis comprovados pelos coeficientes de determinação ($R^2_{máx}$) entre 0,25 a 0,53 e pelos erros médios relativos mínimos ($EMR_{mín}$) entre 30,10 e 48,81.

Os desempenhos das RNAs para as previsões da umidade ótima, do mini-CBR após 24 h de imersão e da contração obtidos na umidade ótima na energia intermediária foram mais satisfatórios do que os para a energia normal. Já para as previsões da massa específica seca máxima, do mini-CBR na umidade de moldagem e da expansão obtidos na umidade ótima ocorreu o oposto, ou seja, os resultados da energia normal foram melhores que os da energia intermediária.

Observa-se que as RNAs que apresentaram os melhores resultados para a previsão das propriedades geotécnicas de interesse tiveram como variáveis de entrada, além das propriedades “alvo” para previsão na outra energia, o valor de azul (V_a), o coeficiente de atividade (CA) e a análise granulométrica do solo (frações do solo passadas nas peneiras de abertura nominal de 0,42 mm, 0,074 mm e 0,005 mm). Os modelos de RNAs implementados que incluíam outras variáveis, como parâmetros da classificação MCT (c' , P_i , d' e e') e classificação por cores (croma, valor e matiz), não proporcionaram bons resultados.

Segundo RODGHER *et al.* (1997), a utilização da técnica de RNAs mostrou-se eficiente para a classificação de solos tropicais. Nesse estudo, verificou-se que, através de ensaios laboratoriais mais simples, rápidos e de fácil assimilação por parte dos técnicos envolvidos na área rodoviária, como a adsorção de azul de metileno pelo método da mancha e a análise granulométrica por peneiramento, foi possível prever a classe MCT dos solos testados. Observou-se também nesse trabalho, que houve um desempenho satisfatório das RNAs na previsão de algumas propriedades geotécnicas dos solos.

Baseando-se nos resultados aqui apresentados e em outros, conclui-se que as RNAs são ferramentas promissoras para a previsão de algumas propriedades geotécnicas de interesse tais como a umidade ótima, massa específica seca máxima e contração nas energias normal e intermediária. Contudo, há necessidade de se considerar as combinações entre as variáveis de entrada para cada modelo especificadamente, para que os dados de entrada permitam uma melhor previsão do dado de saída. Cabe ressaltar que todas as conclusões estão vinculadas aos solos estudados e pertencentes à região de São Carlos (SP), podendo-se adaptar os modelos a qualquer região considerando suas características peculiares.

Para melhorar o desempenho das RNAs para a previsão de algumas das propriedades, talvez torne-se necessário dispor de uma base de dados maior que a utilizada nesta pesquisa, ou ainda usar a mesma base de dados, mas com partições diferentes.

7.5. RNAs *VERSUS* REGRESSÕES MÚLTIPLAS

Os modelos de regressões múltiplas para previsão das umidades ótimas na energia normal e intermediária (expressões 6.1, 6.2 e 6.3), da massa específica seca máxima na energia intermediária (expressão 6.6 e 6.7), do mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária (expressão 6.12) e da contração obtida na umidade ótima na energia normal (expressão 6.16 e 6.17) apresentaram resultados similares aos correspondentes obtidos das RNAs, comprovando o bom desempenho alcançado pelas RNAs para estas propriedades.

Os modelos de regressão para massa específica seca máxima na energia normal (expressão 6.4 e 6.5), expansões obtidas nas umidades ótimas na energias normal (expressão 6.14) e intermediária (expressão 6.15) e contração obtida na umidade ótima na energia intermediária (Figura 6.18) apresentaram coeficientes de determinação (R^2) inferiores aos dos modelos das RNAs para as mesmas variáveis.

Os modelos de regressão para mini-CBR na umidade de moldagem obtidos nas umidades ótimas nas energias normal (expressão 6.8 e 6.9) e intermediária

(expressão 6.10) e mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal apresentaram coeficientes de determinação(R^2) superiores aos dos modelos das RNAs para as mesmas variáveis.

O desempenho das RNAs para previsão de oito das doze propriedades geotécnicas mostrou um comportamento semelhante ou melhor quando comparado com os modelos de regressão múltipla.

Cabe salientar que a dificuldade encontrada nesse estudo e que pode “influenciar” o método de previsão de propriedades geotécnicas dos solos através das RNAs é a qualidade dos resultados obtidos em ensaios laboratoriais para a caracterização e classificação dos solos, uma vez que esses resultados consistem em leitura e cálculo de parâmetros, elementos cuja qualidade pode ser afetada por imprecisões que caracterizam todo trabalho experimental.

De maneira geral, os resultados desse estudo sugerem que, em termos de facilidade de aplicação, os modelos que fazem uso de Redes Neurais Artificiais para a previsão de propriedades geotécnicas dos solos apresentam-se como um método acessível também a outras regiões brasileiras, podendo ser adaptado e implantado para novas características apresentadas pelos solos de outro município qualquer.

REFERÊNCIAS BIBLIOGRÁFICAS

- AMERICAN SOCIETY TESTING AND MATERIALS. (1990) *Annual book of ASTM standards*. Section 4: Construction, v. 04.08: Soil and rock; dimension stone; geosynthetic. Philadelphia.
- AGRAWAL, R. K.; *et al.* (1995) *A novel technique for phase selection based on fault generated high frequency noise using Neural Networks* – Notas de aula do Curso ministrado na EESC-USP.
- ATTONH-OKINE, N. O. (1994) *Predicting roughness progression in flexible pavements*, San Antonio, Texas, Maio 22-26.
- BALLINI, R. (1996) *Previsão Chuva/Vazão*. Dissertação (Mestrado) - EESC , Universidade de São Paulo. São Carlos SP.
- BANAN, M. R.; HJELMSTAD, K. D. (1996). *Neural networks and AASHO road test*. Journal of Transportation Engineering , vol. 122 n° 5 358.
- BEALE, R.; JACKSON, T. (1994). *Neural Computing: na introduction*. Bristol Publishes.
- BENSON, C. H.; ZHAI, H.; WANG, X. (1994) *Estimating hydraulic conductivity of compacted clay liners*. Journal of Geotechnical Engineering, ASCE, v.120, n.2, p.366-387.
- BHAT, N. V. *et al.* (1990) *Modelling chemical process systems via neural computation*. *IEEE Control Systems* 10 (3):24-30.
- BIELLI, M.; REVERBERI, P. (1996). *New operations research and artificial intelligence approaches to traffic engineering problems*. European Journal of Operational Research, p.550-572.

- BREGA, J. R. F. (1996). *A utilização de redes neurais artificiais em um sistema de gerência de pavimentos*. São Carlos. 221p. Tese (Doutorado). - EESC. Universidade de São Paulo.
- BRONDINO, N. C. M. (1999) *Estudo da Influência da Acessibilidade na Valorização de Lotes Urbanos através do Uso de Redes Neurais*. São Carlos. 141p. Tese (Doutorado) - EESC , Universidade de São Paulo.
- CAL, Y. (1995). *Soil classification by neural network*. Engineering Software. Elsevier Science Limited. p.95-97.
- CARVALHO, André C. P. L. F. de (1997). Redes neurais artificiais. In: <http://www.icmsc.sc.usp.br/~andre/>, 15/03/97.
- CARVALHO, A. C. P. L. F.; BRAGA, A.; LUDERMIR, T. (1998) *Fundamentos de Redes Neurais Artificiais*. Publicação da COPPE/UFRJ. XI Escola de Computação Brasileira. Rio de Janeiro.
- CASANOVA, F. J. (1986) *O Ensaio de Azul de Metileno na Caracterização de Solos Lateríticos*. In: REUNIÃO ANUAL DE PAVIMENTAÇÃO, 21, ABPv, Salvador, Anais vol.2, p. 276-286.
- CASSA, J. C. S.; CUNHA NETO, E. D. (1996). *Previsão de propriedades de materiais de pavimentação através de Redes Neurais Artificiais*. In: REUNIÃO ANUAL DE PAVIMENTAÇÃO, 30, Salvador, 1995. Anais. Bahia.
- CHOU, C. J.; LIAU, T. (1996) *Development of automated algorithms for pavement condition survey*. Transportation Research Record 1536, p.103-109.
- COUTINHO NETO, B. (2000) *Redes Neurais Artificiais como procedimento para Retroanálise de Pavimentos Flexíveis*. 119p. Tese (Dissertação) - EESC , Universidade de São Paulo. São Carlos SP.
- COUTINHO NETO, B.; RODGHER, S. F.; FABBRI, G. T. P. (1999) *Retroanálise de Pavimentos Flexíveis através Redes Neurais Artificiais*. In: Congresso de pesquisa e ensino em transportes, 13. São Carlos SP, 1999.
- COSTA NETO, P. L. O. (1988) *Estatística*. Editora Edgard Blücher Ltda. 264p.
- CROOKS, T. (1992) *Care and feeding of neural networks*. AI Expert, v.7, n.7, p.36-41.

- DER-SP – Departamento de Estradas de Rodagem do Estado de São Paulo. *Manual de Normas: pavimentação*. São Paulo, DER-SP, 1991.
- DNER – Departamento Nacional de Estradas de Rodagem. *Métodos de ensaios*. Rio de Janeiro, DNER, 1968.
- DOWLA, F. U.; ROGERS, L. L. (1995) *Solving problems in environmental engineering and geosciences with artificial neural networks*. Cambridge, MIT Press. 240p.
- DYMINSKI, A. S.; RIBEIRO, E. P. (1995) *Rede neural: uma nova técnica na modelagem de solos residuais*. In: GEOJOVEM, 2. PUC-Rio. p.467-475.
- DYMINSKI, A. S.; RIBEIRO, E. P.; ROMANEL, C.; PEDREIRA, C.E. (1996) *Modelagem de Ensaios de cisalhamento direto em Solo Residual utilizando Redes Neurais*. In: CILAMCE, 16. Curitiba PR. p.684-692.
- ELDIN, N. N.; SENOUCCI, A. B. (1994) *Use of artificial neural networks for condition rating of jointed concrete pavements*. Advance in Engineering Software 23, p. 133-141.
- ELLIS, G. W.; YAO, C.; ZHAO, R.; PENUMADU, D. (1995) *Stress-strain modeling of sands using artificial neural networks*. Journal of Geotechnical Engineering, ASCE, v.121, n.5, p.429-435.
- ESPINDOLA, C. R.; MILLER, L. C. (1979) *Solos da Sociedade Agrícola Tabajara*. Cosmopolis.
- FABBRI, G. T. P. (1994) *Caracterização da Fração Fina de Solos Tropicais através da Adsorção de Azul de Metileno*. Tese (Doutorado) - EESC, Universidade de São Paulo. São Carlos SP.
- FABBRI, G. T. P.; SÓRIA, M. H. A. (1991) *Aplicação do Ensaio de Azul de Metileno à Classificação de Solos - Uma Primeira Aproximação*. Anais da XXV Reunião Anual de Pavimentação, ABPV, São Paulo, v.1 p 381-399.
- FAGHRI, A; HUA, J. (1992a). *Evaluation of artificial neural network applications in transportation engineering*. Transportation Research Record 1358, p.71-80.
- FAGHRI, A; HUA, J. (1992b). *Trip generation analysis by artificial neural networks*. Proceedings of the 4th International Conference on Microcomputers in Transportation, Baltimore, 16-18 maio.

- FLINTSCH, G. W.; ZANIEWSKI, J. P.; DELTON, J. (1996) *Artificial neural network for selecting pavement rehabilitation projects*. Transportation Research Record 1524, p.185-193.
- FLOOD, I.; KARTAM, N. (1994a). *Neural networks in civil engineering I: principles and understanding*, Journal of Computing in Civil Engineering, v. 8, n 2, p.131-148.
- FLOOD, I.; KARTAM, N. (1994b). *Neural networks in civil engineering II: systems and application. computers and geomechanics*, Journal of Computing in Civil Engineering, v. 8, n 2, p.149-162.
- FURTADO, A N. D. (1998) *Uma Nova Abordagem na Avaliação de Projetos de Transporte: O Uso de Redes Neurais Artificiais como Técnica para Avaliar e Ordenar Alternativas*. Tese (Doutorado) - EESC , Universidade de São Paulo. São Carlos SP.
- FWA, T. F.; CHAN, W. T.; (1993). *Priority rating of highway maintenance needs by neural networks*. Journal of Transportation Engineering of the ASCE, v. 119 n° 3 p.419-432.
- FWA, T. F.; CHAN, W. T.; TAN, C. Y. (1996). *Genetic-algorithm programming of road maintenance and rehabilitation*. Journal of Transportation Engineering , v. 122 n° 3 p.246-253.
- GARRETT Jr., J. H. (1994) *Where and why artificial neural networks are applicable in Civil Engineering*. Journal of Computing In Civil Engineering, v.8, n.2, p.129-130.
- GHABOUSSI, J. (1992) *Potencial applications of neuro-biological computational models in geotechnical engineering*. In: Numerical Models in Geomechanics, p.543-555. Rotterdam, Balkema
- GHABOUSSI, J.; SIDARTA, D. E. e LADE, P. V. (1994) *Neural Network based Modeling in Geomechanics*. Proceedings of the Computer Methods and Advances in Geomechanics, vol. 3, A A Balkema, Rotterdam.
- GODOY, H.; BERNUCCI, L. B. e NOGAMI, J. S. (1996) *Diretrizes para a Identificação Expedida de Solos Lateríticos para Uso em Obras Viárias*. Anais da XXX Reunião Anual de Pavimentação, ABPv, Salvador, vol.2, pp 557-568.

- GOH, A T.C. (1995). *Modeling soil correlations using neural networks*. Journal of Computing in Civil Engineering, ASCE, v.9, n. 4, p.275-278.
- GOH, A T.C. (1997). *Discussion: Modeling soil correlations using neural networks*. Journal of Computing in Civil Engineering, ASCE, v.11, n. 1, p.79.
- GOH, A T.C.; WONG, K. S.; BROMS, B. B. (1995). *Estimation of lateral wall movements in braced excavations using neural networks*. Canadian Geotechnical Journal, v.32, n. 6, p.1059-1064.
- HACHICH, W.; NADER, J. J. (1992) *Correlações entre parâmetros: análise crítica*. In: SOLOS DA CIDADE DE SÃO PAULO, ABMS/NRSP. p. 181-192.
- HANISCH, W. S.; MILARÉ, C. R.; CARVALHO, A C. P. L. F.; PIRES, E. P. (1996) *Modelagem preliminar de uma estação de tratamento de esgotos utilizando redes neurais*. In: III Simpósio Brasileiro de Redes Neurais. Recife PE, p.271-278.
- HAYKIN, S. (1994). *Neural Networks: a comprehensive foundation*. IEEE Press. Toronto.
- HECHT-NIELSEN R. (1987). *Theory of the backpropagation neural network*. Proc. IJCNN (Washington) DC, p.18-22.
- HERTZ, J.; A. KROGH e R. G. PALMER (1991) *Introduction to the theory of Neural Computation*. Redwood city, Addison-Wesley.
- HSIAO, C. H.; LIN, C. H.; CASSIDY, M. (1994). *Application of Fuzzy Logic and neural networks to automatically detect freeway traffic incidents*. Journal of Transportation Engineering, p.753-772.
- HUA, J.; FAGHRI, A (1993). *Dynamic traffic pattern classification using artificial neural network*. Transportation Research Record 1399, p.14-19.
- HUA, J.; FAGHRI, A (1993). *Traffic mark classification using artificial neural network*. Proceedings of the ASCE International Conference on Applications of Advanced Technologies in Transportation Engineering, Seattle, Washington, USA, p.244-245.
- HUANG, X. P.; PANT, P. D. (1995). *Simulation-neural network model for evaluating dilemma zone problems at high-speed signalized intersections*. Transportation Research Record 1456, p.34-42.

- IONNIDES, A. M.; ALEXANDER, D. R.; HAMMONS, M. I.; DAVIS, C. M. (1996) *Application of artificial neural networks to concrete pavement joint*. Transportation Research Record 1540, p. 56-64.
- IVAN, J. N.; SCHOFER, J. L.; KOPPELMAN, F. S.; MASSONE, L. L. E. (1995) *Real-Time data fusion for arterial street incident detection using neural networks*. Transportation Research Record 1497, p.27-35.
- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. (1996). *Artificial neural networks: A tutorial*. Computer, v. 29, n.3, p. 31-44.
- KASEKO, M. S.; LO, Z. P.; RITCHIE, S. G. (1995). *Comparison of traditional and neural classifiers for pavement crack detection*. Journal of Transportation Engineering, V. 120, N. 4, p.552-569.
- KASEKO, M. S.; RITCHIE, S. G. (1993). *A neural network-based methodology for pavement crack detection and classification*. Transportation Research v. 1 n° 4, p.275-291.
- KOVÁCS, Z. L. (1996) *Redes Neurais Artificiais. Fundamentos e Aplicações*. São Paulo, Edição Acadêmica.
- KU SCHOOL OF ARCHITECTURE & URBAN DESIGN (2000) University of Kansas. Marvin Hall – Lawrence – Kansas 66045. Disponível na Internet:<<http://www.arce.ukans.edu/book/color/classif.htm#3-5>.
- LAN, T. N. (1977) *Un Nouvel Essai D'identification des Sols - L'essai au Bleu de Méthylène*. Bulletin de Liaison des Laboratoires des Ponts et Chaussées, (88):136-137.
- LAN, T. N. (1980) *L'Essai au Bleu de Méthylène: un progrès dans la mesure et le contrôle de la propreté des granulats*. Bulletin de Liaison des Laboratoires des Ponts et Chaussées, (107):130-135.
- LAN, T. N. (1981) - *Utilisation de l'Essai au Bleu de Methylene en Terrassement Routier*. Bulletin de Liaison des Laboratoires des Ponts et Chaussées. (111):5-16.
- LAUTRIN, D. (1981). *Une Procédure Rapide d' Identification des Argiles*. Bulletin de Liaison des Laboratoires des Ponts et Chaussées. (152):75-84.
- LEE, I. M.; LEE, J. H. (1996). *Prediction of pile bearing capacity using artificial neural networks*. Computers and Geotechnics, v.18, n.3, p.189-200.

- LEMOS, R.C.; SANTOS, R.D. (1996) *Manual de descrição e coleta de solo no campo*. 3. ed. Campinas: SBCS/EMBRAPA-CNPS, 1996. Campinas, SP.
- LOLLO, J. A.; ZUQUETTE, L. V. (1996) *Perspectiva de utilização de redes neurais artificiais na avaliação de terreno com finalidades geotécnicas*. In: Congresso Brasileiro de Geologia de Engenharia, 8. Rio de Janeiro, RJ, setembro.
- MEIER, R. W.; RIX, G. J. (1994) *Backcalculation of Flexible Pavement Moduli Using Artificial Neural Networks* Transportation Research Record 1448, p.75-82.
- MINSKY, M. L.; PAPER, S.A. (1969). *Perceptrons: An introduction to computational geometry*. (Cambridge: MIT Press).
- MORA, M. R. (1993) *Análise crítica das classificações de solos para fins rodoviários usadas no Brasil. Proposta e adequação para a região metropolitana da Grande São Paulo*. Dissertação de Mestrado - EESC, Universidade de São Paulo. São Carlos SP.
- MORRIS, A. J. *et al.* (1994) *Artificial Neural Networks: studies in process modelling and control*. *Trans IchemE*, vol. 72, pp.3-19
- MUNSELL SOIL COLOR CHARTS (1975) Soiltest inc. Macbeth a division of Kollmorgen Corporation. Baltimore Maryland USA. 16 fls.
- NAJJAR, Y. M.; BASHEER, I. A. (1996). *Utilizing computational neural networks for evaluating the permeability of compacted clay liners*. *Geotechnical and Geological Engineering*, v.14, n.3, p.193-212.
- NAJJAR, Y. M.; *et al.* (1996). *On the identification of compaction characteristics by neuronets*. *Computers and geotechnics*, v. 18, n 3. p.167-187.
- NAKATSUJI, T.; KAKU, T. (1991). *Developing of a self-organizing traffic control system using neural network models*. *Transportation Research Record* 1324, p.137-145.
- NOGAMI, J. S. (1972) *Determinação do Índice de Suporte Califórnia com Equipamento de Dimensões Reduzidas – Ensaio Mini-CBR*. II Reunião das Administração Rodoviárias. Brasília, DF.
- NOGAMI, J. S. *et al.* (1993) *Pavimentação com Solos Lateríticos*. In: *Solos do Interior de São Paulo*. Anais. p.315-335. São Carlos, SP.

- NOGAMI, J. S., VILLIBOR, D. F. (1980) *Caracterização e Classificação Gerais de Solos para Pavimentação: Limitações do Método Tradicional*. In: REUNIÃO ANUAL DE PAVIMENTAÇÃO, 15. Anais ABPv. Belo Horizonte, MG.
- NOGAMI, J. S., VILLIBOR, D. F. (1981) *Uma Nova Classificação de Solos para Finalidades Rodoviárias*. In: SIMPÓSIO BRASILEIRO DE SOLOS TROPICAIS EM ENGENHARIA. Separata. Rio de Janeiro.
- NOGAMI, J. S., VILLIBOR, D. F. (1985) *Additional Considerations about a New Geotechnical Classification for Tropical Soils*. In: International Conference on Geomechanics in Tropical Lateritic and Saprolitic Soils, 1, Proceeding. P. 165-174. TropicalS'85, ABMS. Brasília, DF.
- NOGAMI, J. S.; VILLIBOR, D. F. (1996) *Importância e Determinação do Grau de Laterização em Geologia de Engenharia*. In: CONGRESSO BRASILEIRO DE GEOLOGIA DE ENGENHARIA, 8. Anais ABGE, Rio de Janeiro, vol. 1, p. 345-358.
- OLIVEIRA, J. B.; JACOMINE, P. K. T.; CAMARGO, M. N. (1992). *Classes Gerais de Solos do Brasil – Guia auxiliar para seu reconhecimento*. UNESP. FUNEP.
- OWUSU-ABABIO, S. (1995) *Modelling skid resistance for flexible pavements: a comparison between regression and neural network models*. Transportation Research Record 1501, p.60-71.
- PACHECO, M.AC.; ABELÉM, AJ.; VELLASCO, M.B.R. (1995) *Modelagem de Redes Neurais Artificiais para Previsão de Séries Temporais*. In: Simpósio Brasileiro de Redes Neurais, 2. p. 107, ICMSC, São Carlos SP.
- PANT, P. et al. (1993). *Neural-network-based procedure for condition assessment of utility cuts in flexible pavements*. Transportation Research Record 1399, p.8-13.
- PARSONS, A W. (1976) *The Rapid Measurement of the Moisture Condition of Earthwork Material*. Transport and Road Research Laboratory, Report N° 750
- PARREIRA, A. B. (1995) *Notas de aula: Fundamentos da Infra-Estrutura dos Transportes*. STT/EESC, São Carlos, SP.
- PEDROSA, I. (1982) *Da cor à cor inexistente*, Universidade de Brasília, 3.ed., Brasília, DF.

- PEJON, O. J. (1992) *Mapeamento Geotécnico Regional da Folha de Piracicaba - SP (Escala 1:100.000): Estudo de Aspectos Metodológicos, de Caracterização e de Apresentação de Atributos*. Tese (Doutorado) - EESC, Universidade de São Paulo. São Carlos SP.
- PHANT, P. D.; ZHOU, X.; ARUDI, R. S.; BODOCSI, A.; AKTAN, A. E. (1996). *Neural-network-based procedure for condition assessment of utility cuts in flexible pavements*. Transportation Research Record, nº 1399 p.8-13.
- PRADO, H. (1993). *Manual de Classificação de Solos do Brasil*. UNESP. FUNEP.
- PRADO, H.; C. L. P. ALMEIDA e J. B. OLIVEIRA (1981) *Levantamento Pedológico Semidetalhado do Estado de São Paulo: Folha de Brotas, Descalvado e São Carlos*. Convênio EMBRAPA/CPA/IA, esc:1:1000,000, Campinas.
- PRECHELT, L. (1994) *PROBEN 1: A Set of Neural Network Benchmark Problems and Benchmarking Rules*. Technical Report 21/94, Fakultät für Informatik, Universität Karlsruhe, Alemanha.
- RANDOLPH, D. A. (1996). *Application of neural network technology to highway maintenance management*. Transportation Research Record, nº 1533 p.3-10.
- RICH, E.; KNIGHT, K. (1993) *Inteligência Artificial*. São Paulo. 2ª ed. Ed. Makron Brooks, Cap. 18, p. 562-568.
- RICH, E.; KNIGHT, K.; SEJNOWSKI, T. S.; ROSENBERG, C. R. (1994) *Parallel Networks that learn to pronounce English Text*. Complex Systems 1 145.
- RODGHER, S. F.; FABBRI, G. T. P.; CARVALHO, A. C. P. L. F. de. (1997). *A Utilização de Redes Neurais Artificiais para Classificação de Solos Tropicais*. In: Congresso de Pesquisa e Ensino em Transportes, 10. Anais (1). p. 51-59 Rio de Janeiro RJ, 1997.
- RODGHER, S. F.; ODA, S. (1997) *Previsão de defeitos em estradas não pavimentadas através do uso de redes neurais artificiais*. In: 1º Simpósio Internacional de Pavimentação de Rodovias de Baixo Volume de Trafêgo, Anais (2). p. 617-626 Rio de Janeiro RJ, 1997.
- RODGHER, S. F.; ODA, S.; FERNANDES, J. L.; FABBRI, G. T. P.; SÓRIA, M. H. A. (1998) *Uso de Redes Neurais Artificiais na seleção de atividades de*

- manutenção e reabilitação de estradas não-pavimentadas*. In: Congresso De Pesquisa e Ensino em Transportes, 12. Fortaleza CE, 1998.
- ROSENBLATT, F. (1958) *The Perceptron: a probabilistic model for information storage and organization in the brain*. Psychological Review, n.65, p.386-408.
- RUMELHART, D.; HINTON, G.; WILLIAMS, R. (1986) *Learning Internal Representations by Error Propagation*. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, 1: Foundations, pp.318-362, MIT Press, Cambridge, Massachusetts.
- SHIKOURY, S. N.; MARTINELLI, D. R. (1996). *Neural network interpretation of ultrasonic response for concrete condition assessment*. Transportation Research Record 1532, 80-86.
- SMITH, B. L.; DEMETSKY, M. J. (1992). *Short-Term traffic flow prediction: neural network approach*. Transportation Research Record 1453, 98-104.
- SÓRIA, M. H. A. (1985) *Reflexões Lógicas sobre Classificação de Solos*. Tese (Doutorado) - EESC, Universidade de São Paulo. São Carlos SP.
- SÓRIA, M. H. A.; FABBRI, G. T. P. (1980) *O ensaio Mini-MCV – Um ensaio de MCV, Moisture Condition Value, com corpos de prova de dimensões reduzidas*. 15ª Reunião Anual de pavimentação. Belo Horizonte, MG.
- STEIN, R. (1993a). *Selecting data for neural networks*. AI Expert, v. 8, n.2, p.42-47.
- STEIN, R. (1993b). *Preprocessing data for neural networks*. AI Expert, v. 8, n.3, p.32-37.
- TAHA, M.; HANNA, A S. (1995) *Evolutionary neural network model for the selection of pavement maintenance strategy*. Transportation Research Record 1497, 70-76
- TAYLOR, C.; DEIRDRE, M. (1994). *Freeway traffic data prediction via artificial neural networks for use in a fuzzy logic ramp metering algorithm*. Proceedings of the Intelligent Vehicles, 14-17 outubro, Paris.
- TUBB, N. R. (1993) *A Development Path to Success in Neural Computing Expert Systems Applications*. Vol. 9, n. 5, p. 5-9.

- XU, Q.; HUANG, R. Q. (1994) *Artificial Neural Network Methods for Spatial Prediction of Slope Stability*. In: International Iaeg Congress, 7, Proceedings. Rotterdam, Balkema. P. 4725-4728.
- ZHANG, O.; SONG, J.; NIE, X. (1991). *Application of neural network models to rock mechanics and rock engineering*. International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, v. 28, n.6, p.535-540.
- VILLIBOR, D. F.; J.S. NOGAMI; P. R. M. SERRA e A. Z. NETO (1996) *A importância dos solos tropicais em pavimentação*. In: Reunião de Pavimentação Urbana, 7. p. 165-186, São José dos Campos SP.
- VUKADINOVI, K.; TEODOROVIC, D.; PAVKOVIC, G.; ROSIC, S. (1996) *A neural network approach to mitigation of vehicle schedule disturbances*. Transportation Planning and Technology v. 20, p. 93-102.
- WEI, C.; CHANG, C.; WANG, S. (1996) *Vehicle classification using advanced technologies*. Transportation Research Record 1551, 45-50.
- WOLSTENHOLME, S. (2001). *EasyNN* 7.5. Inglaterra.
steve@tropheus.demon.co.uk

ANEXO A

**LOCALIZAÇÃO DAS AMOSTRAS, CLASSE PEDOLÓGICA,
CLASSIFICAÇÃO MCT, MASSA ESPECÍFICA DOS SÓLIDOS**

Localização das amostras, Classe Pedológica, Classificação MCT, Massa Específica dos Sólidos

Amostra	Trecho	Margem	Classe pedológica	MCT	δ g/cm ³
01	SC – Babilônia Km 2	esquerda	LE	LA'	2,647
02	SC – Babilônia km 4	esquerda	LV	LG'	2,619
03	SC – Babilônia km 6	direita	LR	LA'	2,692
04	SC – Babilônia km 7	esquerda	TE	LG'	2,887
05	SC – Babilônia km 10	esquerda	LE	LG'	2,917
06	Babilônia – Represa do 29 km 15	esquerda	AQ	NA'	2,671
07	SC – Babilônia km 13	esquerda	LE	LG'	2,369
08	Próximo ao entroncamento com a Represa do 29 km 18,9	esquerda	LE	LG'	2,853
09	Próximo a entrada de Água Vermelha km 27	direita	LV	LA'	2,697
10	Trevo do Condomínio Samambaia (talude)	direita	LV	LG'	2,698
11			LV	NA'	2,766
12	Estrada acima do Condomínio Samambaia à 500 m da Fazenda Floresta	direita	LV	LA'	2,737
13	Estrada de acesso ao Condomínio Tibaia de São Fernando	direita	LE	LG'	2,973
14	Tibaia de São Fernando	direita	LE	LG'	2,887
15	Tibaia de São Fernando próximo a Chácara Primavera	esquerda	LE	LG'	2,714
16	Estrada Tibaia de São Fernando – Represa do 29	esquerda	AQ	NA	2,700
17	SP 318 SC – Ribeirão Preto próximo ao Ribeirão da Água Branca	direita	LR	LG'	2,635

Localização das amostras, Classe Pedológica, Classificação MCT, Massa Específica dos Sólidos

Amostra	Trecho	Margem	Classe pedológica	MCT	δ g/cm ³
18	SP 318 SC – Ribeirão Preto próximo à Chácara Santa Cecília	direita	AQ	LA'	2,636
19	SP 318 SC – Ribeirão Preto próximo à Fazenda Alamo	direita	LR	NA'	2,770
20	SP 318 SC – Ribeirão Preto próximo à Fazenda Alamo	direita	LR	LA'	2,977
21	SP 318 SC – Ribeirão Preto km 260 + 200 m	direita	LR	LG'	2,758
22	SP 318 SC – Ribeirão Preto próximo ao Córrego do Santa Cândida	direita	AQ	NA	2,614
23	SP 318 SC – Ribeirão Preto próximo à Fazenda Dallas	esquerda	PV	NG'	2,712
24	SP 318 SC - Ribeirão Preto próximo à Fazenda Dallas	esquerda	PV	LG'	2,724
25	SP-310 SC-SP km 225+600 m (pista sul)	direita	AQ	LA	2,605
26	SP-310 SC-SP km 222+800 m (pista norte)	direita	AQ	LA	2,624
27	SP-310 SC-SP km 218+200 m (retomo da Sobloco)	direita	AQ	NA	2,611
28	Estrada SC-Descalvado à 4,5 km do Trevo	direita	LV	LG'	2,638
29	Estrada Descalvado-SC à 8,5 km do Trevo	direita	LV	NG'	2,718
30	SP-215 SC-RB à 8 km do Trevo	direita	AQ	NA	2,687
31	SP-215 SC-RB à 14 km do Trevo	direita	LR	NG'	2,718
32	SP-215 SC-RB à 18 km do Trevo	direita	LV	NA	2,551
33	SP-215 SC-RB à 22 km do Trevo	direita	LV	LA'	2,583
34	Estrada Água Vermelha-Santa Eudóxia à 2 km do Trevo	direita	LV	LA'	2,643

Localização das amostras, Classe Pedológica, Classificação MCT, Massa Específica dos Sólidos

Amostra	Trecho	Margem	Classe pedológica	MCT	δ g/cm ³
35	Estrada Água Vermelha-Santa Eudóxia à 6 km do Trevo	direita	LE	LG'	2,766
36	Estrada Água Vermelha-Santa Eudóxia à 8,5 km do Trevo	esquerda	LR	LG'	2,801
37	Estrada Água Vermelha-Santa Eudóxia à 11 km do Trevo	direita	LR	LG'	2,975
38	Estrada Água Vermelha-Santa Eudóxia à 14 km do Trevo	direita	LR	LG'	2,955
39	Estrada Água Vermelha-Santa Eudóxia à 17 km do Trevo	direita	LR	LG'	3,082
40	Estrada Água Vermelha-Santa Eudóxia à 19 km do Trevo	direita	LE	LA'	2,748
41	Estrada Água Vermelha-Santa Eudóxia à 21 km do Trevo	esquerda	LE	NA'	2,627
42	Estrada Água Vermelha-Santa Eudóxia à 30 km do Trevo	esquerda	TE	LG'	3,053
43	Estrada Água Vermelha-Santa Eudóxia à 31 km do Trevo	esquerda	Li	NS'	2,655
44	Estrada Água Vermelha-Santa Eudóxia à 26 km do Trevo	direita	LR	LG'	2,845
45	Estrada Água Vermelha-Santa Eudóxia à 29 km do Trevo	esquerda	LV	LA'	2,622
46	Estrada da Faz. Canchin à 2 km do Trevo da UFSCar	direita	LV	LG'	2,310
47	Estrada da Faz. Canchin à 5 km do Trevo da UFSCar	direita	LV	LA'	2,698
48	Estrada da Faz. Canchin à 7 km do Trevo da UFSCar	direita	LV	LA'	2,696
49	Estrada da Faz. Canchin à 8 km do Trevo da UFSCar	direita	LR	LG'	2,539
50	Estrada da Faz. Canchin à 11 km do Trevo da UFSCar	direita	LE	LG'	2,824
51	Estrada da Faz. Canchin à 12 km do Trevo da UFSCar	direita	AQ	NA'	2,634

Localização das amostras, Classe Pedológica, Classificação MCT, Massa Específica dos Sólidos

Amostra	Trecho	Margem	Classe pedológica	MCT	δ g/cm ³
52	Estrada da Faz. Canchin à 16 km do Trevo da UFSCar	esquerda	LE	LG'	3,005
53	Estrada da Faz. Canchin à 25 km do Trevo da UFSCar	esquerda	LR	LG'	2,851
54	Estrada da Faz. Canchin à 30 km do Trevo da UFSCar	esquerda	LR	LG'	2,834
55	Estrada da Faz. Canchin à 36 km do Trevo da UFSCar	esquerda	LV	NA'	2,659
56	SP 318 SC – Ribeirão Preto à 2 km do Trevo	direita	LV	LA'	2,407
57	SP 318 SC – Ribeirão Preto à 7 km do Trevo	direita	LV	LA'	2,627
58	SP 318 SC – Ribeirão Preto à 10 km do Trevo	direita	LV	LG'	2,643
59	SP 318 SC – Ribeirão Preto à 14 km do Trevo	direita	LV	LA'	2,607
60	SP 318 SC – Ribeirão Preto à 16 km do Trevo	direita	LV	LG'	2,654
61	SP 318 SC – Ribeirão Preto à 28 km do Trevo	direita	LV	LA'	2,627
62	SP 318 SC – Ribeirão Preto (entrada da Fazenda Faroeste) à 31,5 km do Trevo	direita	LV	LA'	2,580
63	SP 318 SC – Ribeirão Preto (entrada da Fazenda Faroeste) à 35 km do Trevo	direita	LV	LA'	2,583
64	SP 318 SC – Ribeirão Preto (entrada da Fazenda Faroeste) à 39 km do Trevo	direita	LV	LA'	2,629
65	SP-310 SC-SP à 2 km do Trevo	direita	AQ	NA	2,602
66	SP-310 SC-SP à 5,6 km do Trevo	direita	AQ	NA	2,614
67	SP-310 SC-SP à 11 km do Trevo	direita	AQ	NA	2,632
68	SP-215 SC-RB à 2 km do Trevo	direita	AQ	NA	2,597

Localização das amostras, Classe Pedológica, Classificação MCT, Massa Específica dos Sólidos

Amostra	Trecho	Margem	Classe pedológica	MCT	δ g/cm ³
69	SP-215 SC-RB à 4,5 km do Trevo	direita	AQ	NA	2,591
70	SP-215 SC-Descalvado à 3 km do Trevo	direita	LV	LA'	2,645
71	SP-215 SC- Descalvado à 6,5 km do Trevo	direita	LV	LA'	2,612
72	SP-215 SC- Descalvado à 10,5 km do Trevo	direita	LV	LG'	2,644
73	SP-215 SC- Descalvado à 14 km do Trevo	direita	LV	LA'	2,652
74	SP-215 SC- Descalvado à 16 km do Trevo	direita	LV	LG'	2,643
75	SP-310 SC-AQA à 1,5 km do Trevo	direita	LV	LG'	2,680
76	SP-310 SC-AQA à 4 km do Trevo	direita	LV	LG'	2,605
77	SP-310 SC-AQA à 10 km do Trevo	direita	LV	LA'	2,664
78	SP-310 SC-AQA à 12 km do Trevo	direita	LV	LG'	2,655
79	SP-310 SC-AQA à 15 km do Trevo	direita	LV	LA'	2,637
80	Estrada para Brotas à 800 m do entroncamento (SP-215 SC-RB)	direita	AQ	LA'	2,609
81	Estrada para Brotas à 1 km do entroncamento (SP-215 SC-RB)	direita	AQ	NA'	2,595
82	Estrada para Brotas à 4 km do entroncamento (SP-215 SC-RB)	direita	AQ	NA'	2,586
83	Estrada para Brotas à 7 km do entroncamento (SP-215 SC-RB)	direita	LR	NS'	2,731
84	Estrada para Brotas à 8,2 km do entroncamento (SP-215 SC-RB)	esquerda	Li	NS'	2,494
85	Estrada para Brotas à 9,2 km do entroncamento (SP-215 SC-RB)	esquerda	Li	NA'	2,589

Localização das amostras, Classe Pedológica, Classificação MCT, Massa Específica dos Sólidos

Amostra	Trecho	Margem	Classe pedológica	MCT	δ g/cm ³
86	Estrada para Brotas à 10,3 m do entroncamento (SP-215 SC-RB)	esquerda	PV	NS ⁷	2,567
87	Estrada para Brotas à 11,6 km do entroncamento (SP-215 SC-RB)	esquerda	Li	NS ⁷	2,538
88	Estrada para Brotas à 12,1 km do entroncamento (SP-215 SC-RB)	esquerda	PV	NA ⁷	2,622
89	Estrada para Brotas à 14,1 km do entroncamento (SP-215 SC-RB)	esquerda	Li	NS ⁷	2,617
90	Estrada para Brotas à 15,9 km do entroncamento (SP-215 SC-RB)	direita	LR	LG ⁷	2,855
91	Estrada Água Vermelha-Santa Eudóxia à 6 km do Trevo de acesso	direita	LE	LG ⁷	2,505
92	Estrada Água Vermelha-Santa Eudóxia à 9 km do Trevo de acesso	direita	LR	LG ⁷	2,658
93	Estrada Água Vermelha-Santa Eudóxia à 12 km do Trevo de acesso	direita	LR	LG ⁷	3,032
94	Estrada Água Vermelha-Santa Eudóxia à 14 km do Trevo de acesso	direita	LR	LG ⁷	2,859
95	Estrada Água Vermelha-Santa Eudóxia à 20 km do Trevo de acesso	direita	LE	NA ⁷	2,644
96	Estrada Água Vermelha-Santa Eudóxia à 23 km do Trevo de acesso	direita	LE	LG ⁷	2,824
97	Estrada Água Vermelha-Santa Eudóxia à 25 km do Trevo de acesso	direita	LE	NA ⁷	2,707
98	Estrada Santa Eudóxia-Balsa do Mogi-Guaçu à 2,5 km	direita	LR	NS ⁷	2,595
99	Estrada Santa Eudóxia-Balsa do Mogi-Guaçu à 4 km	direita	LR	LG ⁷	2,614
100	Estrada Santa Eudóxia-Balsa do Mogi-Guaçu à 6 km	direita	LR	LA ⁷	2,595
101	SP 318 SC – Ribeirão Preto (entrada da Fazenda Faroste) à 42 km do Trevo	direita	LV	LA ⁷	2,684

ANEXO B

CLASSIFICAÇÃO HRB (*HIGHWAY RESEARCH BOARD*)

Classificação de solos HRB (*Highway Research Board*)

Espaço

Amostra	classe HRB
1	A-2-6
2	A-7-6
3	A-6
4	A-7-5
5	A-7-5
6	A-2-6
7	A-4
8	A-4
9	A-2-6
10	A-4
11	A-6
12	A-4
13	A-4
14	A-4
15	A-4
16	A-2-6
17	A-4
18	A-2-4
19	A-6
20	A-6
21	A-6
22	A-2-6
23	A-6
24	A-6
25	A-2-4
26	A-2-4
27	A-2-6
28	A-2-7
29	A-7-5
30	A-1-b
31	A-7-5
32	A-1-b
33	A-2-6
34	A-2-4
35	A-4
36	A-4
37	A-7-5
38	A-7-5
39	A-7-5
40	A-2-4
41	A-2-6

Classificação de solos HRB (*Highway Research Board*)

42	A-7-5
43	A-6
44	A-4
45	A-2-4
46	A-2-4
47	A-4
48	A-2-4
49	A-6
50	A-6
51	A-2-4
52	A-7-6
53	A-4
54	A-6
55	A-2-4
56	A-2-4
57	A-2-7
58	A-7-6
59	A-6
60	A-2-4
61	A-2-6
62	A-2-6
63	A-2-6
64	A-2-6
65	A-2-6
66	A-2-6
67	A-2-6
68	A-2-6
69	A-2-6
70	A-6
71	A-4
72	A-6
73	A-2-4
74	A-4
75	A-4
76	A-2-4
77	A-6
78	A-4
79	A-6
80	A-2-6
81	A-2-6
82	A-6
83	A-7-6

Classificação de solos HRB (*Highway Research Board*)

84	A-2-6
85	A-2-6
86	A-2-6
87	A-2-6
88	A-2-6
89	A-2-6
90	A-6
91	A-2-6
92	A-4
93	A-6
94	A-7-6
95	A-2-6
96	A-6
97	A-2-4
98	A-2-6
99	A-2-6
100	A-2-6
101	A-2-6

ANEXO C

**VALOR DE AZUL (VA), COEFICIENTE DE ATIVIDADE (CA) E GRAUS
DE ATIVIDADE**

Valor de azul (Va), Coeficiente de atividade (CA) e Graus de atividade

Amostra	Va (10^{-3} g/g)	CA (10^{-3} g/g%)	Grau de atividade
01	1,40	5,60	Pouco ativo
02	1,69	4,00	Pouco ativo
03	1,71	5,70	Pouco ativo
04	3,53	6,70	Pouco ativo
05	4,94	8,00	Pouco ativo
06	0,63	3,50	Pouco ativo
07	3,28	13,30	Ativo
08	3,28	9,10	Pouco ativo
09	1,31	5,90	Pouco ativo
10	1,02	3,00	Pouco ativo
11	1,30	7,50	Pouco ativo
12	1,59	4,30	Pouco ativo
13	2,73	7,60	Pouco ativo
14	1,88	5,60	Pouco ativo
15	0,76	3,00	Pouco ativo
16	1,02	10,90	Pouco ativo
17	2,53	7,20	Pouco ativo
18	0,91	4,2	Pouco ativo
19	3,90	15,5	Ativo
20	2,52	5,1	Pouco ativo
21	2,03	5,9	Pouco ativo
22	1,84	28,7	Ativo
23	1,00	3,0	Pouco ativo
24	1,31	4,1	Pouco ativo
25	0,64	10,8	Pouco ativo
26	0,97	13,2	Ativo
27	0,65	2,7	Pouco ativo
28	0,61	1,5	Pouco ativo

Valor de azul (Va), Coeficiente de atividade (CA) e Graus de atividade

Amostra	Va (10^{-3} g/g)	CA (10^{-3} g/g%)	Grau de atividade
29	2,85	5,7	Pouco ativo
30	0,51	6,6	Pouco ativo
31	2,10	4,7	Pouco ativo
32	1,18	14,6	Ativo
33	0,98	5,7	Pouco ativo
34	1,50	5,4	Pouco ativo
35	2,20	6,7	Pouco ativo
36	2,53	4,9	Pouco ativo
37	4,16	8,5	Pouco ativo
38	4,98	8,8	Pouco ativo
39	3,38	6,8	Pouco ativo
40	1,40	11,3	Ativo
41	0,26	5,9	Pouco ativo
42	0,70	1,3	Pouco ativo
43	0,66	3,2	Pouco ativo
44	2,77	6,0	Pouco ativo
45	1,05	4,5	Pouco ativo
46	1,54	5,3	Pouco ativo
47	2,20	8,9	Pouco ativo
48	1,49	9,0	Pouco ativo
49	3,23	7,1	Pouco ativo
50	1,61	3,5	Pouco ativo
51	0,51	11,4	Ativo
52	4,91	9,8	Pouco ativo
53	2,52	10,6	Pouco ativo
54	1,59	6,6	Pouco ativo
55	1,60	8,9	Pouco ativo
56	1,42	3,9	Pouco ativo

Valor de azul (Va), Coeficiente de atividade (CA) e Graus de atividade

Amostra	Va (10^{-3} g/g)	CA (10^{-3} g/g%)	Grau de atividade
57	0,84	11,4	Ativo
58	1,52	4,6	Pouco ativo
59	1,36	4,9	Pouco ativo
60	1,45	6,5	Pouco ativo
61	0,84	11,4	Ativo
62	0,92	8,0	Pouco ativo
63	0,58	5,0	Pouco ativo
64	0,65	2,0	Pouco ativo
65	0,43	5,3	Pouco ativo
66	0,24	10,8	Ativo
67	0,28	5,2	Pouco ativo
68	0,40	6,5	Pouco ativo
69	0,11	3,3	Pouco ativo
70	0,90	2,8	Pouco ativo
71	2,13	5,5	Pouco ativo
72	0,92	2,9	Pouco ativo
73	0,77	5,1	Pouco ativo
74	2,39	5,6	Pouco ativo
75	1,32	4,5	Pouco ativo
76	1,46	9,1	Pouco ativo
77	1,30	4,5	Pouco ativo
78	1,29	5,2	Pouco ativo
79	1,55	6,0	Pouco ativo
80	0,55	3,0	Pouco ativo
81	0,28	4,3	Pouco ativo
82	1,50	5,8	Pouco ativo
83	5,62	17,6	Ativo
84	0,29	2,4	Pouco ativo

Valor de azul (Va), Coeficiente de atividade (CA) e Graus de atividade

Amostra	Va (10^{-3} g/g)	CA (10^{-3} g/g%)	Grau de atividade
85	0,24	2,8	Pouco ativo
86	0,31	8,3	Pouco ativo
87	0,21	4,5	Pouco ativo
88	0,40	11,1	Ativo
89	0,14	2,4	Pouco ativo
90	3,53	9,1	Pouco ativo
91	1,87	8,5	Pouco ativo
92	2,72	8,7	Pouco ativo
93	3,79	11,8	Ativo
94	6,11	11,1	Ativo
95	1,91	12,2	Ativo
96	1,61	3,4	Pouco ativo
97	0,76	4,6	Pouco ativo
98	0,51	15,3	Ativo
99	2,05	12,0	Ativo
100	1,34	6,7	Pouco ativo
101	1,62	4,5	Pouco ativo

ANEXO D

**CLASSIFICAÇÃO DOS SOLOS POR CORES (*MUNSELL SOIL COLOR
CHARTS, 1975*)**

Classificação de solos por cores (*Munsell Soil Color Charts*, 1975)

Amostra	matiz (<i>hue</i>)	valor (<i>value</i>)	croma (<i>chroma</i>).
01	5 YR	6	3
02	2,5 YR	5	4
03	5 YR	6	4
04	5 YR	4	3
05	5 YR	3	3
06	5 YR	4	3
08	5 YR	5	3
09	2,5 YR	5	4
10	10 YR	6	4
11	10 YR	7	6
12	7,5 YR	6	4
13	7,5 YR	5	4
14	2,5 YR	5	4
15	10 YR	5	2
16	5 YR	5	3
17	2,5 YR	5	6
18	10 YR	6	4
19	2,5 YR	3	6
20	2,5 YR	3	6
21	2,5 YR	3	4
22	5 YR	5	3
23	5 YR	5	4
24	5 YR	5	4
25	5 YR	5	6
26	5 YR	5	4
27	10 YR	7	4
28	5 YR	5	6
29	5 YR	5	4
30	7,5 YR	5	2
31	2,5 YR	3	4
32	5 YR	5	3
33	2,5 YR	4	4
34	10 YR	6	4
35	5 YR	3	4
36	2,5 YR	3	4
37	2,5 YR	4	4
38	2,5 YR	2,5	4
39	2,5 YR	2,5	4
40	5 YR	4	3
41	5 YR	4	3
42	5 YR	4	4
43	10 YR	6	4

Classificação de solos por cores (*Munsell Soil Color Charts*, 1975)

Amostra	matiz (<i>hue</i>)	valor (<i>value</i>)	croma (<i>chroma</i>)
44	2,5 YR	4	4
45	2,5 YR	4	2
46	5 YR	5	4
47	7,5 YR	5	4
48	5 YR	5	4
49	2,5 YR	4	4
50	5 YR	5	3
51	5 YR	5	3
52	2,5 YR	3	4
53	2,5 YR	3	4
54	2,5 YR	4	4
55	5 YR	4	3
56	5 YR	4	4
57	10 YR	6	6
58	7,5 YR	5	4
59	5 YR	5	4
60	10 YR	6	6
61	5 YR	5	4
62	2,5 YR	3	4
63	2,5 YR	3	4
64	5 YR	6	4
65	5 YR	6	6
66	5 YR	6	4
67	10 YR	6	6
68	10 YR	5	3
69	10 YR	6	4
70	10 YR	6	4
71	10 YR	6	4
72	5 YR	7	3
73	2,5 YR	5	2
74	5 YR	5	4
75	10 YR	6	4
76	10 YR	5	3
77	5 YR	5	3
78	7,5 YR	6	4
79	10 YR	6	3
80	5 YR	5	3
81	5 YR	4	2
82	5 YR	5	3
83	2,5 YR	4	2
84	10 YR	7	3

Classificação de solos por cores (*Munsell Soil Color Charts*, 1975)

Amostra	matiz (<i>hue</i>)	valor (<i>value</i>)	croma (<i>chroma</i>)
85	10 YR	6	4
86	10 YR	5	2
87	10 YR	5	3
88	5 YR	6	4
89	10 YR	6	4
90	2,5 YR	3	4
91	5 YR	5	3
92	2,5 YR	3	4
93	2,5 YR	4	4
94	2,5 YR	4	4
95	5 YR	5	3
96	5 YR	5	3
97	5 YR	4	3
98	5 YR	5	4
99	2,5 YR	4	4
100	2,5 YR	3	4
101	2,5 YR	4	4

ANEXO E

CLASSIFICAÇÃO MCT E GRANULOMETRIA

Classificação MCT e Granulometria

Amostra	MCT	c'	d'	Pi	e'	4,76 mm	2,00 mm	1,19 mm	0,59 mm	0,297 mm	0,149 mm	0,074 mm	0,005 mm	0,002 mm
01	LA'	1,20	65	65	0,99	100,00	100,00	99,64	94,31	76,68	46,92	33,77	24,85	23,57
02	LG'	2,03	132,5	38	0,81	100,00	100,00	99,58	96,80	83,42	62,51	54,35	42,53	39,79
03	LA'	1,35	43,64	78	1,07	100,00	100,00	99,75	95,47	80,37	53,04	40,83	30,08	28,69
04	LG'	1,54	25,38	58	1,11	100,00	100,00	99,74	97,81	94,19	87,91	83,85	53,03	42,24
05	LG'	1,70	26,72	39	1,04	100,00	100,00	99,26	97,27	94,92	89,86	86,71	62,14	50,84
06	NA'	1,11	35,67	120	1,21	100,00	99,96	99,91	99,56	94,45	41,64	29,98	18,06	17,04
07	LG'	1,65	98,75	104	1,08	100,00	99,63	97,95	93,79	85,54	59,27	49,70	24,74	18,61
08	LG'	1,65	36,80	0	0,82	100,00	100,00	99,76	97,84	92,01	73,40	52,31	36,00	31,11
09	LA'	1,05	61,05	90	1,07	100,00	100,00	99,01	94,98	85,93	55,59	32,02	22,11	20,78
10	LG'	1,90	145,45	10	0,62	100,00	100,00	99,63	95,10	76,84	59,19	50,15	34,59	34,8
11	NA'	1,30	41,54	135	1,22	100,00	99,83	99,49	92,57	70,09	52,47	42,74	17,30	16,42
12	LA'	1,40	66,00	85	1,05	100,00	100,00	99,85	95,32	74,41	57,87	51,55	37,00	35,81
13	LG'	1,60	50,00	100	1,12	100,00	100,00	99,98	98,84	87,33	70,43	63,99	35,92	29,16
14	LG'	1,65	130,56	22	0,72	100,00	100,00	99,96	99,29	92,08	61,03	46,00	33,77	31,29
15	LG'	1,40	60,63	58	0,97	100,00	100,00	99,86	96,62	74,13	46,22	36,96	25,45	24,22
16	NA	0,40	29,38	210	1,41	100,00	100,00	99,90	98,46	81,96	38,86	19,92	9,40	8,21
17	LG'	1,51	124,12	10,00	0,64	100,00	100,00	99,36	95,84	81,88	55,40	46,57	35,01	32,96

Classificação MCT e Granulometria

Amostra	MCT	e'	d'	Pi	e'	4,76 mm	2,00 mm	1,19 mm	0,59 mm	0,297 mm	0,149 mm	0,074 mm	0,005 mm	0,002 mm
18	LA'	1,02	19,31	40,00	1,13	100,00	100,00	99,09	95,13	75,70	37,17	28,81	21,77	19,74
19	NA'	1,28	58,62	122,00	1,16	100,00	100,00	99,33	96,89	82,66	57,59	46,47	25,06	19,62
20	LA'	1,31	42,27	104,00	1,15	100,00	100,00	99,80	99,07	95,94	84,25	81,01	49,28	40,28
21	LG'	1,53	100,83	117,00	1,11	100,00	100,00	99,98	99,49	93,35	68,24	64,96	34,66	31,53
22	NA	0,34	24,29	311,70	1,58	100,00	100,00	99,95	99,35	90,43	38,48	29,90	6,4	5,22
23	NG'	1,67	22,38	90,00	1,22	100,00	100,00	99,54	96,99	80,17	49,36	46,81	32,9	29,53
24	LG'	1,54	69,41	11,60	0,74	100,00	100,00	99,66	98,37	85,37	51,57	41,85	32,04	29,89
25	LA	0,46	34,12	20,00	0,92	100,00	100,00	99,13	95,35	76,77	39,93	31,93	5,93	5,34
26	LA	0,32	25,00	25,00	1,02	100,00	100,00	99,12	95,32	76,65	39,62	31,58	7,31	8,09
27	NA	0,34	16,25	252,00	1,47	100,00	100,00	99,13	95,36	76,84	40,11	32,13	23,83	22,97
28	LG'	1,87	98,26	98,20	1,06	100,00	100,00	99,06	95,01	75,07	35,53	26,95	39,76	36,22
29	NG'	1,77	4,35	30,00	1,70	100,00	99,96	98,75	96,29	87,36	68,99	63,75	50,00	48,77
30	NA	0,52	50,00	193,00	1,33	100,00	99,98	97,51	90,29	69,63	26,05	16,59	7,83	6,03
31	NG'	2,25	7,60	101,00	1,54	100,00	100,00	99,73	98,98	94,29	72,83	62,41	45,00	39,67
32	NA	0,58	32,00	109,00	1,20	100,00	99,95	97,37	90,27	70,14	29,23	18,91	8,09	9,00
33	LA'	0,93	132,86	49,60	0,86	100,00	100,00	99,11	95,24	76,24	38,56	30,38	17,33	15,32

Classificação MCT e Granulometria

Amostra	MCT	c'	d'	Pi	e'	4,76 mm	2,00 mm	1,19 mm	0,59 mm	0,297 mm	0,149 mm	0,074 mm	0,005 mm	0,002 mm
51	NA'	0,60	22,00	315,00	1,60	100,00	100,00	99,92	99,61	83,22	33,85	16,61	4,49	3,92
52	LG'	1,88	111,05	100,00	1,06	100,00	100,00	99,78	98,90	95,33	81,99	73,45	50,00	42,22
53	LG'	1,51	40,45	80,00	1,09	100,00	100,00	99,68	98,75	88,26	55,83	44,08	23,83	19,12
54	LG'	1,66	52,00	65,00	1,01	100,00	100,00	99,61	98,65	88,29	55,83	44,10	24,05	20,30
55	NA'	1,05	78,95	263,1	1,42	100,00	100,00	99,86	92,25	75,88	42,04	28,86	17,96	16,26
56	LA'	1,48	88,50	97,00	1,06	100,00	99,88	99,20	97,28	87,05	45,25	26,30	36,02	33,32
57	LA'	0,78	64,72	65,00	0,99	100,00	100,00	100,00	97,19	82,11	39,41	18,32	7,36	8,79
58	LG'	1,61	73,24	40,00	0,88	100,00	100,00	99,66	94,68	78,74	53,26	45,49	33,11	30,47
59	LA'	1,40	99,13	5,00	0,63	100,00	100,00	99,63	94,63	72,93	45,29	39,90	27,94	29,38
60	LG'	1,70	103,53	62,00	0,93	100,00	99,95	99,36	90,98	72,23	39,28	31,20	22,20	20,92
61	LA'	0,78	64,72	65,00	0,99	100,00	100,00	100,00	97,19	82,11	39,41	18,32	7,36	8,79
62	LA'	0,81	56,88	107,00	1,12	100,00	100,00	99,93	99,55	94,87	38,38	20,33	11,56	10,26
63	LA'	0,72	71,74	100,00	1,09	100,00	100,00	100,00	99,36	90,93	37,63	18,97	11,54	10,24
64	LA'	1,23	114,55	87,00	1,01	100,00	100,00	99,88	96,87	82,95	45,96	30,57	33,07	30,44
65	NA	0,48	32,86	108,90	1,19	100,00	100,00	99,90	99,45	84,10	48,82	21,27	8,12	7,22

Classificação MCT e Granulometria

Amostra	MCT	c'	d'	Pi	e'	4,76 mm	2,00 mm	1,19 mm	0,59 mm	0,297 mm	0,149 mm	0,074 mm	0,005 mm	0,002 mm
66	NA	0,42	21,11	312,00	1,60	100,00	100,00	99,40	94,50	79,50	27,88	11,98	2,25	3,96
67	NA	0,20	25,50	245,00	1,48	100,00	99,83	98,23	93,58	84,34	37,54	13,99	5,45	4,54
68	NA	0,40	9,00	310,00	1,75	100,00	100,00	98,90	88,73	66,89	24,26	12,73	6,11	3,98
69	NA	0,34	6,92	295,00	1,80	100,00	100,00	99,95	98,65	76,41	27,44	10,82	3,35	3,98
70	LA'	1,12	78,34	65,00	1,06	100,00	99,81	99,46	94,28	77,75	50,32	42,40	32,18	27,73
71	LA'	1,42	87,50	75,00	0,99	100,00	99,88	99,44	94,35	78,44	55,45	49,12	38,59	36,76
72	LG'	1,84	71,56	100,00	1,09	100,00	99,81	99,46	94,28	77,75	50,32	42,40	32,18	27,73
73	LA'	0,83	23,33	50,00	1,11	100,00	100,00	99,61	95,41	76,50	34,84	24,71	15,23	13,39
74	LG'	1,32	24,08	60,00	1,09	100,00	100,00	99,68	95,77	85,41	64,69	56,74	43,08	38,62
75	LG'	1,68	205,00	90,00	1,00	100,00	100,00	99,70	96,23	82,54	51,03	41,21	29,08	28,09
76	LG'	1,67	64,72	95,00	1,08	100,00	100,00	99,70	93,71	73,76	42,40	33,71	15,96	13,58
77	LA'	1,40	69,26	78,00	1,02	100,00	100,00	99,95	93,99	73,75	46,62	38,05	28,86	24,29
78	LG'	1,67	177,33	104,00	1,05	100,00	100,00	99,88	96,07	77,95	45,74	36,73	25,00	24,23
79	LA'	1,39	76,67	20,00	0,77	100,00	100,00	99,81	96,82	80,73	46,46	36,22	25,59	22,92
80	LA'	1,31	106,36	6,00	0,63	100,00	100,00	99,66	96,62	73,47	36,29	27,30	18,15	18,21
81	NA'	0,69	14,17	250,00	1,58	100,00	99,92	98,68	96,58	76,68	25,57	13,60	6,39	2,57
82	NA'	1,06	63,75	150,00	1,22	100,00	100,00	99,86	97,86	83,49	49,56	36,87	25,72	25,99

Classificação MCT e Granulometria

Amostra	MCT	c'	d'	Pi	e'	4,76 mm	2,00 mm	1,19 mm	0,59 mm	0,297 mm	0,149 mm	0,074 mm	0,005 mm	0,002 mm
83	NS'	1,40	6,82	90,00	1,57	100,00	100,00	99,57	96,55	90,37	76,17	68,37	31,86	23,71
84	NS'	1,19	38,82	310,00	1,53	100,00	100,00	100,00	99,97	93,52	63,84	28,48	12,17	12,45
85	NA'	1,04	39,00	189,00	1,34	100,00	100,00	99,97	99,60	96,88	66,61	24,30	8,59	5,93
86	NS'	0,69	10,00	325,00	1,74	100,00	100,00	99,75	99,35	97,33	40,99	15,12	3,70	3,97
87	NS'	0,94	16,09	260,00	1,57	100,00	99,78	99,44	98,70	93,36	50,68	20,62	4,61	4,67
88	NA'	0,70	38,24	310,00	1,54	100,00	100,00	99,95	99,82	95,26	59,17	20,01	3,65	6,64
89	NS'	0,84	20,50	330,00	1,62	100,00	100,00	99,98	99,86	99,35	21,16	13,79	5,92	4,61
90	LG'	2,08	145,56	109,00	1,07	100,00	100,00	99,65	99,17	96,65	64,30	53,61	39,00	35,86
91	LG'	2,13	66,11	109	1,12	100,00	100,00	99,78	94,23	71,89	40,64	32,73	21,96	19,00
92	LG'	1,70	37,50	91,00	1,13	100,00	100,00	99,41	95,33	79,99	57,98	50,12	31,23	25,55
93	LG'	1,66	69,29	100,00	1,09	100,00	100,00	99,69	97,53	91,74	74,84	66,60	32,00	22,53
94	LG'	2,02	72,17	100,00	1,08	100,00	100,00	99,73	97,63	94,11	86,39	81,96	55,00	45,41
95	NA'	1,19	28,64	115,00	1,23	100,00	100,00	99,64	98,27	93,19	45,96	30,32	15,64	11,44
96	LG'	1,88	86,25	65,00	0,96	100,00	100,00	99,76	98,82	95,21	81,84	73,26	47,50	42,22

Classificação MCT e Granulometria

Amostra	MCT	c'	d'	Pi	e'	4,76 mm	2,00 mm	1,19 mm	0,59 mm	0,297 mm	0,149 mm	0,074 mm	0,005 mm	0,002 mm
97	NA'	1,23	90,80	155,00	1,21	100,00	100,00	100,00	99,56	87,52	42,94	25,01	16,62	13,85
98	NS'	0,77	17,50	315,00	1,63	100,00	100,00	99,92	98,49	78,90	28,53	12,61	3,35	3,24
99	LG'	1,65	51,88	81,00	1,06	100,00	100,00	99,88	99,24	92,38	49,63	32,82	17,07	12,85
100	LA'	1,41	73,43	89,00	1,05	100,00	100,00	99,95	98,90	88,59	50,40	31,86	19,90	18,42
101	LA'	1,44	96,92	23,00	0,76	100,00	100,00	99,58	95,73	83,51	60,02	50,91	36,23	36,84

ANEXO F

**RESULTADOS DOS ENSAIOS DE LIMITE DE LIQUIDEZ E DE
PLASTICIDADE**

Resultados dos ensaios de limite de liquidez e de plasticidade

Amostra	LL	LP	IP
01	28,95	16,36	12,59
02	40,70	25,55	15,15
03	32,20	19,55	12,65
04	52,50	39,99	12,51
05	50,50	37,89	13,11
06	NL	NP	-
08	32,20	22,63	9,57
09	24,65	17,13	7,52
10	39,50	26,19	13,31
11	NL	NP	-
12	32,45	22,33	10,12
13	38,40	29,48	8,92
14	33,20	22,50	10,70
15	30,38	20,66	9,72
16	NL	NP	-
17	35,40	NP	-
18	27,60	17,73	9,87
19	31,60	21,40	10,20
20	40,30	16,04	24,26
21	40,76	29,00	11,76
22	NL	NP	-
23	34,20	20,95	13,25
24	35,00	24,09	10,91
25	NL	NP	-
26	NL	NP	-
27	NL	NP	-
28	40,70	28,97	11,73
29	50,00	34,92	15,08
30	NL	NP	-
31	41,30	30,36	10,94
32	NL	NP	-
33	31,70	19,61	12,09
34	31,60	21,45	10,15
35	36,37	25,36	11,01
36	32,80	23,64	9,16
37	44,70	33,72	10,98
38	53,70	37,52	16,18
39	43,70	31,24	12,46
40	NL	NP	-
41	NL	NP	-
42	46,70	31,52	15,18
43	NL	NP	-
44	36,70	26,15	10,55

Resultados dos ensaios de limite de liquidez e de plasticidade

Amostra	LL	LP	IP
45	25,45	17,47	7,98
46	35,20	23,71	11,49
47	32,70	23,62	9,08
48	NL	NP	-
49	NL	NP	-
50	35,40	23,89	11,51
51	NL	NP	-
52	43,60	24,08	19,52
53	28,30	20,62	7,68
54	35,80	24,17	11,63
55	NL	NP	-
56	30,00	20,96	9,04
57	42,40	26,41	15,99
58	41,70	26,69	15,01
59	35,80	24,28	11,52
60	31,60	22,24	9,36
61	34,40	20,99	13,41
62	NL	NP	-
63	NL	NP	-
64	NL	NP	-
65	NL	NP	-
66	NL	NP	-
67	NL	NP	-
68	NL	NP	-
69	NL	NP	-
70	38,80	25,67	13,13
71	33,60	23,21	10,39
72	37,00	23,87	13,13
73	NL	NP	-
74	38,30	30,36	7,94
75	32,60	22,04	10,56
76	29,70	21,76	7,94
77	35,40	20,98	14,42
78	33,00	22,91	10,09
79	34,20	18,93	15,27
80	NL	NP	-
81	NL	NP	-
82	NL	NP	-
83	41,23	28,11	13,12
84	NL	NP	-
85	NL	NP	-
86	34,60	21,65	12,95
87	NL	NP	-

Resultados dos ensaios de limite de liquidez e de plasticidade

Amostra	LL	LP	IP
88	34,40	21,49	12,91
89	NL	NP	-
90	36,40	24,60	11,80
91	37,56	25,60	11,96
92	31,54	21,08	10,46
93	34,60	23,30	11,30
94	40,10	27,29	12,81
95	39,23	26,93	12,30
96	40,02	27,56	12,46
97	30,20	19,75	10,45
98	37,11	25,12	11,99
99	38,32	26,00	12,32
100	36,90	24,97	11,93
101	34,56	19,12	15,44

ANEXO G

**RESUMO DAS PROPRIEDADES DOS SOLOS NA UMIDADE ÓTIMA
PARA A ENERGIA NORMAL
E
RESULTADOS DOS ENSAIOS DE MINI-CBR, EXPANSÃO E CONTRAÇÃO
NA ENERGIA NORMAL**

Resumo das propriedades dos solos na umidade ótima para a energia normal

Amostra	Umidade Ótima (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediateo)	Mini-CBR (24h)
01	12,82	1,901	0,00	0,70	35,0	21,0
02	17,20	1,780	0,00	1,20	15,0	9,0
03	14,90	1,830	0,11	0,86	14,4	12,3
04	28,50	1,478	0,25	1,50	13,5	9,0
05	29,80	1,494	0,18	1,83	12,6	9,3
06	16,40	1,804	0,00	0,74	11,0	6,2
07	18,06	1,682	0,20	0,77	9,3	6,8
08	15,50	1,882	0,00	0,70	35,0	21,0
09	17,30	1,788	0,00	1,12	12,0	8,5
10	17,49	1,745	0,08	0,97	22,0	9,3
11	19,30	1,704	0,01	0,62	20,0	12,0
12	18,47	1,715	0,08	1,06	16,9	12,2
13	15,51	1,896	0,00	0,82	21,2	19,8
14	22,55	1,682	0,20	0,75	13,4	10,0
15	14,50	1,829	0,00	0,65	14,0	10,0
16	9,00	1,889	0,02	0,70	14,0	9,5
17	15,50	1,809	0,04	0,65	16,0	6,0
18	10,00	1,814	0,24	0,16	16,8	10,5
19	16,20	1,834	0,08	0,80	10,7	9,3
20	14,91	1,830	0,09	0,85	13,4	13,0
21	16,00	1,900	0,06	0,90	14,9	9,0
22	5,80	1,786	0,00	0,48	9,3	5,0
23	13,45	1,743	0,36	0,60	8,5	6,0
24	13,47	1,767	0,12	0,60	18,3	6,8
25	10,41	1,921	0,22	0,39	14,2	4,4
26	9,70	1,880	0,01	0,10	11,8	8,5
27	6,50	1,861	0,03	0,13	8,0	3,5
28	17,97	1,760	0,08	0,22	24,2	21,2
29	23,20	1,610	0,04	2,23	18,3	11,1
30	8,00	1,862	0,08	0,03	15,0	9,7
31	22,76	1,710	0,04	1,26	11,0	7,6
32	9,55	1,981	0,08	0,12	30,0	13,4
33	10,52	2,008	0,52	0,41	37,1	22,7
34	14,00	1,880	0,08	0,10	15,0	9,0
35	18,80	1,702	0,14	1,03	9,0	4,1
36	18,90	1,771	0,01	0,90	18,5	13,5
37	27,40	1,571	0,15	1,07	9,0	7,1
38	28,50	1,550	0,15	1,05	8,0	5,7
39	26,20	1,648	0,22	1,20	7,2	4,0
40	14,70	1,860	0,16	0,56	13,0	8,5

Resumo das propriedades dos solos na umidade ótima para a energia normal

Amostra	Umidade Ótima (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
41	9,09	1,808	0,54	0,49	11,5	6,0
42	24,50	1,720	0,26	0,57	20,0	8,6
43	17,20	1,687	0,10	0,68	12,0	9,0
44	20,40	1,750	0,00	1,37	13,0	10,6
45	13,50	1,890	0,14	0,30	20,0	11,0
46	15,00	1,850	0,10	0,45	16,0	11,0
47	14,80	1,830	0,07	0,60	12,0	9,0
48	11,68	1,887	0,00	0,31	19,6	16,0
49	25,90	1,517	0,02	0,86	10,0	5,8
50	18,50	1,710	0,13	1,07	6,5	4,2
51	8,07	1,794	0,08	0,12	13,4	9,9
52	23,82	1,667	0,12	1,82	15,8	10,7
53	15,00	1,940	0,14	1,00	10,8	8,0
54	22,24	1,717	0,04	1,26	13,4	7,6
55	15,50	1,809	0,10	0,62	14,0	9,8
56	16,00	1,820	0,05	0,60	11,0	8,0
57	8,40	1,860	0,07	0,07	19,0	10,0
58	16,60	2,028	0,03	0,31	16,0	11,0
59	16,00	1,860	0,04	0,40	12,0	7,0
60	12,00	1,800	0,08	0,08	27,0	11,8
61	8,50	1,870	0,06	0,07	19,0	10,0
62	9,68	1,831	0,02	0,12	17,5	9,3
63	10,00	1,950	0,05	0,09	19,0	16,0
64	11,79	1,972	0,12	0,30	19,8	14,5
65	10,00	1,918	0,00	0,18	17,0	6,5
66	8,20	1,920	0,01	0,13	7,3	5,2
67	9,80	1,855	0,00	0,14	12,0	5,3
68	6,00	1,810	0,06	0,13	7,5	6,2
69	9,90	1,794	0,08	0,12	13,4	9,9
70	16,80	1,790	0,03	0,26	16,0	12,0
71	16,05	1,819	0,00	0,95	23,4	13,8
72	16,23	1,891	0,00	0,37	16,0	11,5
73	10,80	1,855	0,12	0,35	9,0	8,0
74	19,70	1,701	0,00	0,54	7,6	5,2
75	15,18	1,844	0,12	0,95	14,2	9,3
76	15,19	1,839	0,10	0,54	12,6	9,4
77	15,35	1,840	0,12	1,00	11,0	8,5
78	13,30	1,935	0,00	0,55	10,5	10,0
79	13,43	1,904	0,00	0,54	14,5	10,1
80	12,50	1,774	0,00	0,38	7,0	2,7

Resumo das propriedades dos solos na umidade ótima para a energia normal

Amostra	Umidade ótima (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
81	6,90	1,831	0,00	0,11	6,8	4,4
82	11,60	1,875	0,02	0,26	6,0	4,0
83	18,90	1,446	1,16	1,81	7,6	2,2
84	7,98	1,777	0,08	0,58	6,0	2,2
85	7,36	1,693	0,22	0,18	8,5	2,2
86	8,19	1,651	0,14	0,40	3,2	2,2
87	8,50	1,707	0,00	0,23	15,0	4,0
88	6,05	1,754	0,02	0,18	6,8	5,0
89	6,00	1,684	0,15	0,15	8,0	2,0
90	19,30	1,695	0,00	1,45	3,8	2,7
91	16,20	1,667	0,43	0,94	12,0	7,2
92	17,90	1,760	0,17	1,06	14,0	8,0
93	22,50	1,484	0,38	0,87	7,0	5,7
94	23,65	1,536	0,64	2,12	11,8	6,0
95	14,50	1,793	0,00	0,64	6,0	4,5
96	18,60	1,703	0,10	0,33	5,8	3,5
97	11,50	1,890	0,00	0,36	10,0	6,9
98	9,00	1,777	0,00	0,06	3,2	2,1
99	13,00	1,810	0,00	0,47	4,2	2,1
100	12,20	1,855	0,00	0,43	12,0	8,0
101	17,46	1,771	0,12	0,30	12,2	10,1

Resultados dos ensaios de Mini-CBR, Expansão e Contração na Energia Normal

Amostra 01					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,23	1,798	0,16	0,00	21,2	11,9
11,18	1,844	0,12	0,39	22,7	13,0
12,82	1,901	0,00	0,50	22,0	16,8
14,08	1,847	0,00	0,71	10,7	6,0
15,71	1,780	0,00	0,75	6,8	4,4

Amostra 02					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
14,82	1,596	0,28	0,64	21,2	5,0
16,08	1,701	0,16	0,99	17,5	12,6
17,02	1,780	0,00	1,09	16,8	9,9
18,64	1,732	0,00	1,74	6,8	5,0
20,34	1,572	0,00	1,59	5,0	3,6

Amostra 03					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
11,50	1,690	0,20	0,48	20,5	5,9
13,58	1,783	0,14	0,64	18,3	10,1
15,08	1,829	0,10	0,86	14,2	12,2
17,59	1,704	0,06	1,08	8,1	7,6
20,08	1,681	0,00	1,30	6,8	5,2

Amostra 04					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
24,84	1,407	0,46	0,15	12,6	6,4
26,38	1,450	0,31	0,63	13,4	8,1
28,17	1,477	0,27	1,26	13,8	9,2
31,41	1,461	0,15	2,99	7,6	7,2
34,16	1,400	0,09	3,26	4,1	3,6

Amostra 05					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
24,80	1,405	0,80	2,06	18,3	6,8
27,87	1,466	0,93	2,01	17,3	11,4
31,04	1,484	0,18	1,82	12,6	9,3
32,94	1,463	0,00	1,67	9,3	6,0
35,55	1,405	0,00	2,20	4,1	3,6

Amostra 06					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
12,23	1,750	0,15	0,46	19,0	8,5
13,54	1,775	0,06	0,59	14,6	9,9
15,18	1,794	0,00	0,69	15,3	15,3
16,80	1,797	0,00	0,77	9,3	5,9
18,24	1,736	0,00	0,81	5,0	5,2

Amostra 07					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
12,93	1,509	0,84	0,31	11,8	2,7
15,15	1,619	0,41	0,45	11,8	4,4
18,06	1,682	0,20	0,77	9,3	6,8
19,95	1,637	0,08	1,18	5,0	4,1
22,23	1,515	0,00	1,22	3,6	3,2

Amostra 08					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
13,05	1,794	0,26	0,38	55,3	12,6
13,78	1,824	0,06	0,62	44,2	21,2
15,31	1,881	0,00	0,69	37,8	22,0
16,84	1,871	0,00	0,79	17,5	10,7
19,19	1,810	0,00	0,92	12,2	8,0

Amostra 09					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
14,48	1,681	0,04	0,19	16,9	1,4
15,84	1,747	0,02	0,72	19,0	4,4
16,98	1,783	0,00	0,88	19,0	10,6
17,44	1,785	0,00	1,13	11,0	11,5
18,26	1,754	0,00	1,23	4,4	7,6



Amostra 10					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
15,35	1,511	0,20	0,42	19,0	3,6
16,08	1,617	0,08	0,51	23,5	15,8
17,49	1,745	0,07	0,96	22,0	9,3
18,46	1,566	0,06	1,03	13,8	6,0
19,24	1,453	0,02	1,59	7,6	5,0

Amostra 11					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
15,92	1,627	0,16	0,38	19,8	11,8
17,29	1,653	0,04	0,47	22,0	15,8
18,55	1,693	0,02	0,58	20,5	17,5
19,42	1,701	0,00	0,63	19,0	11,1
21,07	1,679	0,00	0,71	6,8	5,2

Amostra 12					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
16,49	1,569	0,13	0,78	17,5	7,2
17,12	1,658	0,10	1,12	17,5	12,6
18,47	1,715	0,08	1,05	16,9	12,2
20,38	1,667	0,05	1,16	8,1	7,6
22,09	1,636	0,00	1,44	5,5	5,9

Amostra 13					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,52	1,761	0,04	0,50	22,7	6,0
14,16	1,848	0,02	0,64	22,0	11,0
15,51	1,896	0,00	0,82	21,2	19,8
17,03	1,857	0,00	0,92	19,6	13,8
18,19	1,823	0,00	1,35	9,5	9,3

Amostra 14					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
19,42	1,588	0,39	0,60	16,8	6,8
20,91	1,625	0,31	0,65	17,7	10,3
22,41	1,680	0,20	0,71	13,4	10,1
23,37	1,669	0,16	0,81	9,3	5,6
24,53	1,652	0,00	1,10	4,4	2,7

Amostra 15					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,95	1,481	0,19	0,17	24,5	1,2
11,13	1,665	0,04	0,44	24,2	5,9
13,17	1,808	0,00	0,58	21,2	13,0
15,41	1,810	0,00	0,69	9,7	12,6
17,46	1,679	0,00	0,88	6,8	5,2

Amostra 16					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,63	1,829	0,02	0,02	18,3	4,4
6,96	1,860	0,02	0,39	23,5	11,8
8,34	1,886	0,02	0,59	19,8	11,5
9,74	1,885	0,02	0,80	8,1	7,6
11,08	1,879	0,00	1,01	4,4	6,0

Amostra 17					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,75	1,521	0,16	0,25	46,3	3,6
12,48	1,684	0,08	0,34	26,4	10,7
14,55	1,765	0,06	0,50	16,6	15,0
15,79	1,802	0,04	0,66	15,3	5,2
20,57	1,594	0,04	0,72	9,3	2,2

Amostra 18					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,68	1,584	0,40	0,00	25,6	1,2
9,09	1,750	0,30	0,08	19,0	9,2
9,93	1,814	0,24	0,15	16,8	11,0
11,12	1,777	0,14	0,21	21,9	3,6
12,73	1,666	0,06	0,28	14,5	2,2

Amostra 19					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,15	1,582	0,23	0,34	23,5	2,2
12,01	1,606	0,13	0,42	17,5	3,2
14,01	1,741	0,09	0,67	13,0	6,8
16,20	1,834	0,07	0,79	10,7	9,3
19,35	1,754	0,02	1,18	3,6	2,7

Amostra 20					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,70	1,687	0,20	0,44	21,2	6,8
13,62	1,783	0,14	0,66	17,5	11,0
15,17	1,827	0,10	0,88	13,4	13,0
17,85	1,700	0,05	1,10	8,0	8,0
20,12	1,682	0,00	1,30	7,2	5,5

Amostra 21					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,84	1,689	0,06	0,36	24,2	2,7
14,08	1,824	0,06	0,64	17,5	7,6
15,83	1,899	0,06	0,89	15,0	9,2
17,73	1,852	0,04	0,98	9,3	4,1
18,75	1,811	0,02	1,01	4,4	5,0

Amostra 22					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,02	1,651	0,06	0,00	17,5	3,6
4,43	1,736	0,04	0,20	15,8	6,8
5,90	1,765	0,02	0,28	10,1	6,8
6,70	1,700	0,00	0,24	9,3	5,0
8,11	1,659	0,00	0,71	9,3	4,4

Amostra 23					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,72	1,526	0,82	0,25	15,3	1,2
12,47	1,678	0,60	0,58	11,5	5,2
13,45	1,743	0,36	0,59	8,5	6,0
14,22	1,615	0,04	0,64	11,8	4,4
15,78	1,509	0,02	0,99	7,6	2,7

Amostra 24					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,32	1,561	0,82	0,27	24,9	1,2
12,25	1,695	0,50	0,52	21,2	1,2
13,47	1,767	0,12	0,60	18,3	6,8
16,00	1,700	0,02	0,69	7,6	6,8
17,22	1,564	0,00	0,90	1,2	1,2

Amostra 25					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,75	1,856	0,83	0,12	11,5	1,2
8,15	1,870	0,35	0,13	16,6	3,6
9,36	1,892	0,27	0,21	11,8	5,2
10,41	1,921	0,22	0,38	14,2	4,4
13,40	1,884	0,14	0,46	11,0	1,2

Amostra 26					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,38	1,802	0,02	0,08	14,2	4,4
7,60	1,822	0,02	0,08	11,8	10,1
9,23	1,876	0,02	0,10	11,8	9,3
10,85	1,868	0,00	0,10	11,8	6,0
12,30	1,801	0,00	0,12	7,6	3,6

Amostra 27					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,30	1,766	0,10	0,02	10,7	1,2
3,02	1,790	0,07	0,02	16,8	4,1
3,52	1,849	0,04	0,07	15,0	5,0
4,89	1,792	0,00	0,13	15,3	6,8
5,59	1,766	0,00	0,14	12,2	5,2

Amostra 28					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
14,39	1,563	0,14	0,09	25,6	7,6
16,41	1,723	0,12	0,12	24,2	17,3
17,97	1,760	0,08	0,22	24,2	21,2
19,32	1,715	0,02	0,43	16,0	14,2
20,95	1,628	0,00	0,45	8,5	9,3

Amostra 29					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
20,81	1,542	0,07	2,05	18,3	11,8
22,95	1,610	0,04	2,22	18,3	11,0
24,95	1,573	0,04	2,56	10,1	14,5
26,96	1,517	0,00	2,58	7,6	6,0

Amostra 30					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,45	1,695	0,22	0,02	22,0	4,1
6,47	1,822	0,10	0,02	16,8	9,3
8,26	1,861	0,08	0,04	13,4	9,3
9,20	1,775	0,04	0,10	11,0	6,0
9,60	1,717	0,00	0,10	9,3	4,4

Amostra 31					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
18,43	1,646	0,06	1,03	17,3	6,8
21,09	1,686	0,06	1,10	21,2	14,2
22,76	1,710	0,04	1,25	11,0	7,6
24,41	1,667	0,02	1,63	6,8	6,0
25,39	1,635	0,00	1,68	5,2	2,2

Amostra 32					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,93	1,854	0,18	0,04	38,7	1,9
7,93	1,920	0,12	0,08	19,8	7,6
9,55	1,981	0,08	0,12	30,0	13,4
10,46	1,900	0,02	0,13	20,5	12,6
12,25	1,820	0,00	0,14	2,2	2,2

Amostra 33					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,29	1,798	0,79	0,27	38,6	10,1
8,71	1,925	0,68	0,30	30,0	9,3
10,52	2,008	0,52	0,41	37,1	22,7
12,06	1,944	0,51	0,49	16,0	14,5
15,84	1,857	0,32	0,71	2,2	2,2

Amostra 34					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,11	1,676	0,10	0,04	16,6	1,9
12,83	1,861	0,09	0,07	16,6	8,5
15,36	1,863	0,06	0,11	11,8	6,8
16,26	1,821	0,04	0,14	7,6	3,6
20,02	1,674	0,02	0,13	2,2	1,2

Amostra 35					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
16,20	1,520	0,16	0,74	6,0	1,2
17,54	1,686	0,14	0,92	5,9	3,6
20,19	1,692	0,12	1,13	6,0	4,1
22,37	1,630	0,04	1,17	3,6	2,7
24,39	1,501	0,00	1,22	3,2	1,9

Amostra 36					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
13,77	1,519	0,38	0,36	26,4	2,2
15,07	1,522	0,20	0,38	18,3	2,2
17,47	1,703	0,17	0,75	17,5	11,8
19,10	1,765	0,00	0,92	16,6	13,0
20,89	1,535	0,00	0,93	4,1	6,0

Amostra 37					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
20,88	1,352	0,52	0,50	10,1	1,2
24,91	1,521	0,19	0,92	12,6	4,4
25,73	1,560	0,16	1,01	11,8	6,8
28,54	1,561	0,14	1,10	7,6	6,8
32,26	1,368	0,13	1,07	2,7	3,2

Amostra 38					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
23,48	1,416	0,24	0,22	5,0	2,7
25,89	1,487	0,22	0,52	11,5	6,8
28,02	1,548	0,17	0,99	9,9	5,9
29,30	1,535	0,12	1,11	4,4	5,2
30,16	1,423	0,04	1,33	5,0	4,4

Amostra 39					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
18,22	1,391	0,85	0,26	21,2	2,2
22,58	1,462	0,59	0,49	21,2	3,2
25,52	1,643	0,28	1,09	6,8	4,4
27,57	1,618	0,14	1,17	6,0	3,6
30,29	1,374	0,11	1,22	1,9	2,2

Amostra 40					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,33	1,731	0,33	0,24	12,6	5,9
11,95	1,758	0,28	0,43	12,6	6,8
13,17	1,810	0,21	0,53	12,6	9,9
14,86	1,857	0,16	0,57	12,6	8,5
17,18	1,739	0,12	0,95	3,6	4,1

Amostra 41					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,68	1,753	0,87	0,14	15,3	2,2
5,31	1,805	0,65	0,14	20,4	4,4
7,43	1,854	0,64	0,27	15,0	6,8
9,09	1,808	0,54	0,48	11,5	6,0
11,13	1,753	0,14	1,10	2,7	3,2

Amostra 42					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
20,18	1,509	0,38	0,28	48,4	3,6
23,70	1,709	0,30	0,53	31,5	7,6
25,36	1,703	0,20	0,59	11,8	6,0
27,54	1,565	0,10	0,67	6,8	5,2
28,48	1,520	0,02	0,92	6,8	4,1

Amostra 43					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
13,58	1,526	0,26	0,26	13,0	5,9
14,82	1,620	0,15	0,45	18,3	7,6
16,68	1,690	0,10	0,58	12,6	10,1
18,47	1,595	0,08	0,86	9,3	6,0
20,37	1,533	0,04	0,95	3,6	3,6

Amostra 44					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
15,70	1,543	0,37	0,46	41,4	4,4
17,47	1,620	0,02	0,87	18,1	9,9
20,11	1,751	0,00	1,34	13,4	11,0
23,10	1,687	0,00	1,50	17,3	6,8
25,23	1,637	0,00	1,50	5,2	2,2

Amostra 45					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,79	1,634	0,36	0,08	27,8	3,6
10,69	1,822	0,24	0,16	25,7	6,8
12,03	1,860	0,20	0,22	24,2	8,5
14,02	1,882	0,11	0,32	17,5	11,0
16,23	1,659	0,08	0,45	6,8	5,2

Amostra 46					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
9,62	1,557	0,32	0,28	22,0	1,2
12,24	1,750	0,18	0,29	19,0	9,3
14,40	1,845	0,10	0,42	18,9	12,6
16,13	1,822	0,08	0,49	10,7	6,8
18,52	1,569	0,00	0,72	5,2	4,4

Amostra 47					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
10,63	1,669	0,23	0,46	15,8	3,6
12,53	1,783	0,10	0,53	15,8	6,8
14,21	1,819	0,08	0,56	15,8	9,3
16,39	1,794	0,04	0,67	6,8	6,8
18,47	1,666	0,02	0,89	3,6	2,2

Amostra 48					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
7,61	1,738	0,10	0,14	24,9	8,4
9,82	1,852	0,00	0,26	21,9	13,8
11,68	1,887	0,00	0,30	19,6	16,0
13,44	1,853	0,00	0,35	8,4	10,7
16,16	1,758	0,00	0,36	3,2	3,6

Amostra 49					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
21,91	1,401	0,18	0,54	18,9	2,7
23,03	1,454	0,02	0,69	16,8	5,2
24,53	1,489	0,02	0,75	15,8	8,5
26,26	1,513	0,00	0,87	8,5	5,2
29,13	1,423	0,00	0,89	5,0	2,7

Amostra 50					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
16,20	1,520	0,16	0,74	7,6	1,2
17,54	1,686	0,14	0,92	6,8	3,6
19,06	1,708	0,12	1,13	6,0	4,1
20,07	1,661	0,04	1,17	3,6	2,7
21,04	1,543	0,00	1,22	3,2	1,9

Amostra 51					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,56	1,756	0,27	0,11	13,4	5,2
6,16	1,788	0,12	0,12	13,4	6,8
8,07	1,794	0,08	0,12	13,4	9,9
10,27	1,787	0,08	0,14	6,8	5,9
12,77	1,760	0,02	0,16	4,4	5,2

Amostra 52					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
19,21	1,479	0,16	0,80	22,0	2,2
21,51	1,604	0,14	1,00	17,5	11,8
23,82	1,667	0,11	1,81	15,8	10,7
25,31	1,610	0,10	2,30	4,4	6,8
27,26	1,507	0,08	2,48	2,2	3,6

Amostra 53					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,23	1,727	0,20	0,54	16,8	1,9
14,42	1,931	0,16	0,70	15,8	7,6
16,40	1,893	0,06	1,73	3,6	6,0
18,47	1,792	0,00	1,74	1,2	3,6
20,61	1,709	0,00	1,92	1,2	2,2

Amostra 54					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
19,60	1,630	0,06	1,03	17,3	2,7
21,09	1,686	0,06	1,10	21,2	6,0
22,24	1,717	0,04	1,25	13,4	7,6
24,41	1,667	0,02	1,63	6,8	6,0
25,39	1,635	0,00	1,68	5,2	2,2

Amostra 55					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,78	1,575	0,32	0,36	15,8	2,7
13,68	1,750	0,26	0,54	16,6	8,5
14,82	1,804	0,13	0,59	15,3	12,2
16,92	1,778	0,04	0,68	8,5	5,9
19,41	1,587	0,00	0,92	3,2	4,1

Amostra 56					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,30	1,591	0,36	0,32	15,8	2,7
13,68	1,750	0,22	0,56	16,6	8,5
14,82	1,804	0,11	0,57	15,3	12,2
16,92	1,804	0,02	0,66	8,5	5,9
19,41	1,613	0,00	0,94	3,2	4,1

Amostra 57					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,10	1,684	0,12	0,02	19,8	6,0
7,48	1,832	0,10	0,07	21,2	9,3
8,85	1,856	0,06	0,07	17,5	10,1
11,29	1,738	0,04	0,12	13,4	14,5
13,25	1,660	0,02	0,20	1,9	7,6

Amostra 58					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,48	1,544	0,08	0,00	28,1	2,9
14,07	1,941	0,05	0,14	18,9	9,1
16,60	2,020	0,03	0,31	16,0	11,0
18,51	1,809	0,02	0,82	9,7	6,0
19,20	1,502	0,00	0,76	8,0	4,1

Amostra 59					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,74	1,489	0,16	0,00	27,8	2,7
13,77	1,681	0,08	0,04	19,8	8,5
15,63	1,853	0,04	0,30	13,8	7,6
17,01	1,811	0,03	0,71	7,6	5,2
18,52	1,532	0,00	0,74	7,6	3,6

Amostra 60					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,72	1,562	0,12	0,02	43,5	1,2
10,25	1,727	0,10	0,07	36,4	7,6
12,19	1,798	0,08	0,08	26,4	11,8
14,19	1,690	0,04	0,12	19,8	7,6
16,08	1,600	0,02	0,20	11,5	6,0

Amostra 61					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,10	1,694	0,16	0,02	19,8	6,0
7,48	1,832	0,10	0,07	21,2	9,3
8,85	1,865	0,06	0,07	17,5	10,1
11,29	1,757	0,04	0,12	9,3	8,5
13,25	1,724	0,020	0,18	1,9	7,6

Amostra 62					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,48	1,657	0,06	0,04	27,1	3,2
7,53	1,750	0,02	0,04	24,9	5,2
9,68	1,831	0,02	0,12	17,5	9,3
11,81	1,840	0,00	0,20	10,1	3,6
13,51	1,861	0,00	0,22	8,5	1,2

Amostra 63					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,59	1,653	0,12	0,02	46,4	4,4
6,75	1,821	0,10	0,08	40,8	6,8
8,65	1,921	0,06	0,08	26,4	10,7
10,62	1,931	0,04	0,10	15,8	15,3
12,62	1,686	0,02	0,20	11,5	7,6

Amostra 64					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,46	1,619	0,57	0,00	49,8	6,8
10,02	1,918	0,26	0,04	28,5	14,5
11,79	1,972	0,11	0,29	19,8	14,5
13,55	1,814	0,04	0,71	10,1	5,9
15,05	1,604	0,00	0,74	7,6	3,6

Amostra 65					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,95	1,789	0,00	0,06	28,6	2,2
7,06	1,857	0,00	0,11	24,2	4,4
8,96	1,904	0,00	0,17	19,8	8,5
10,52	1,910	0,00	0,19	15,3	5,2
12,89	1,784	0,00	0,24	5,2	2,7

Amostra 66					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,06	1,766	0,18	0,00	21,9	1,2
5,07	1,825	0,15	0,10	13,4	2,7
6,74	1,879	0,04	0,11	11,0	5,2
8,46	1,905	0,00	0,14	6,8	5,0
10,73	1,776	0,00	0,19	4,4	2,7

Amostra 67					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,13	1,825	0,04	0,12	13,4	3,2
7,23	1,847	0,02	0,11	15,0	5,0
9,00	1,847	0,00	0,11	12,6	7,6
10,00	1,855	0,00	0,13	11,5	5,2
11,39	1,810	0,00	0,15	9,3	4,4

Amostra 68					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,74	1,668	0,17	0,00	18,9	1,9
4,70	1,778	0,15	0,10	12,6	3,6
6,34	1,803	0,04	0,12	6,8	6,8
8,03	1,722	0,00	0,14	5,0	5,9
9,95	1,678	0,00	0,19	5,2	3,6

Amostra 69					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,83	1,825	0,04	0,10	24,2	3,6
6,74	1,875	0,02	0,11	18,1	8,5
8,45	1,907	0,00	0,11	14,2	11,5
10,34	1,917	0,00	0,14	11,8	7,6
12,89	1,829	0,00	0,16	11,8	2,2

Amostra 70					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,83	1,483	0,08	0,00	26,4	2,7
14,61	1,739	0,06	0,08	23,5	14,2
17,42	1,782	0,02	0,31	14,2	10,1
20,12	1,636	0,00	0,35	8,5	6,0
23,31	1,480	0,00	0,57	3,2	3,6

Amostra 71					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,55	1,593	0,02	0,20	25,7	5,0
14,06	1,798	0,00	0,50	26,4	13,4
16,05	1,819	0,00	0,95	23,4	13,8
18,02	1,782	0,00	1,04	5,2	6,8
20,25	1,606	0,00	1,10	3,2	3,6

Amostra 72					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,61	1,577	0,04	0,18	28,5	4,1
14,19	1,756	0,02	0,20	24,9	10,1
16,23	1,891	0,00	0,37	16,0	11,5
18,08	1,719	0,00	0,41	4,1	3,2
20,06	1,520	0,00	0,57	3,2	2,7

Amostra 73					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,50	1,618	0,38	0,00	31,4	3,2
7,47	1,718	0,14	0,08	22,7	6,0
9,11	1,794	0,12	0,32	18,3	9,3
10,99	1,847	0,12	0,36	7,6	10,1
13,09	1,614	0,00	0,57	3,2	3,6

Amostra 74					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
14,95	1,479	0,06	0,18	14,2	2,7
17,63	1,658	0,00	0,37	12,2	4,4
19,70	1,701	0,00	0,53	7,6	5,2
20,62	1,665	0,00	0,55	4,4	4,4
23,49	1,466	0,00	0,67	3,6	2,2

Amostra 75					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,30	1,521	0,50	0,20	34,3	3,2
12,48	1,761	0,20	0,51	14,5	7,6
15,18	1,844	0,12	0,95	14,2	9,3
16,83	1,801	0,00	1,03	7,6	6,8
19,63	1,525	0,00	1,10	3,2	3,6

Amostra 76					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,30	1,521	0,22	0,18	15,8	3,2
13,57	1,777	0,18	0,38	15,0	7,6
15,19	1,839	0,10	0,54	12,6	9,3
16,57	1,795	0,00	0,55	5,9	5,9
19,63	1,525	0,00	0,69	3,2	3,6

Amostra 77					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,96	1,636	0,49	0,19	32,9	5,0
13,24	1,711	0,19	0,42	26,4	16,0
15,35	1,839	0,11	0,95	11,0	8,5
17,07	1,782	0,00	1,04	6,8	5,9
19,63	1,627	0,00	1,10	3,2	3,6

Amostra 78					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
9,27	1,615	0,03	0,17	20,5	2,7
11,80	1,775	0,00	0,37	19,0	9,3
13,06	1,929	0,00	0,54	12,2	11,0
14,41	1,898	0,00	0,56	4,4	6,8
16,12	1,619	0,00	0,67	3,2	2,7

Amostra 79					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
9,10	1,652	0,21	0,17	35,0	2,7
11,55	1,818	0,00	0,37	23,5	7,6
13,43	1,904	0,00	0,53	14,5	10,1
15,41	1,845	0,00	0,56	4,4	6,0
17,54	1,665	0,00	0,67	3,6	2,2

Amostra 80					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,33	1,512	0,15	0,05	32,1	1,2
10,54	1,714	0,00	0,28	11,5	1,9
12,92	1,772	0,00	0,39	6,8	2,7
15,80	1,654	0,00	0,42	5,2	1,9
16,76	1,515	0,00	0,49	3,6	1,2

Amostra 81					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,48	1,759	0,00	0,04	16,8	1,9
6,05	1,824	0,00	0,08	8,5	3,6
7,25	1,830	0,00	0,12	6,0	4,4
8,93	1,787	0,00	0,13	3,6	3,2
10,80	1,757	0,00	0,24	3,2	1,9

Amostra 82					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,86	1,659	0,20	0,08	20,5	1,9
8,18	1,751	0,10	0,10	25,7	3,6
9,68	1,842	0,04	0,12	8,5	4,4
12,46	1,862	0,00	0,36	5,2	3,6
14,36	1,656	0,00	0,56	3,2	2,2

Amostra 83					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
13,76	1,333	2,23	0,85	16,0	1,9
16,43	1,391	2,06	1,33	13,0	4,1
18,90	1,446	1,15	1,81	7,6	2,2
20,82	1,366	1,13	1,95	5,0	1,2
22,41	1,349	0,28	2,04	5,0	1,2

Amostra 84					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,12	1,623	0,18	0,35	7,6	1,2
6,18	1,704	0,10	0,50	7,6	1,9
7,98	1,777	0,07	0,58	6,0	2,2
10,07	1,725	0,05	0,64	4,4	1,9
12,52	1,691	0,04	0,95	3,6	1,2

Amostra 85					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,23	1,589	0,41	0,06	22,7	1,2
6,36	1,644	0,37	0,13	10,7	1,9
7,36	1,693	0,21	0,18	8,5	2,2
8,32	1,724	0,13	0,22	8,4	1,9
12,10	1,706	0,00	0,98	8,4	1,2

Amostra 86					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,33	1,591	0,64	0,10	6,8	1,2
6,79	1,605	0,28	0,18	7,6	1,9
8,19	1,651	0,14	0,39	3,2	2,2
9,51	1,632	0,11	0,62	2,2	1,9
11,21	1,624	0,02	0,99	2,2	1,2

Amostra 87					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,38	1,658	0,06	0,20	16,6	1,2
6,87	1,701	0,00	0,21	15,0	1,9
8,82	1,707	0,00	0,23	13,0	4,4
10,38	1,693	0,00	0,31	4,1	2,7
12,52	1,690	0,00	0,46	3,2	1,2

Amostra 88					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,74	1,628	0,22	0,16	24,2	1,2
4,61	1,695	0,11	0,17	6,8	5,2
6,05	1,754	0,02	0,17	6,8	5,0
8,25	1,707	0,00	0,23	6,8	1,9
9,98	1,634	0,00	0,26	5,2	1,2

Amostra 89					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,55	1,627	0,19	0,05	15,0	1,2
5,72	1,682	0,15	0,13	8,4	1,9
7,21	1,665	0,00	0,21	7,6	2,7
8,57	1,595	0,00	0,31	5,2	3,6
11,10	1,503	0,00	0,46	5,0	1,2

Amostra 90					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
14,48	1,387	0,20	0,38	17,5	1,2
16,39	1,546	0,16	1,02	12,2	3,6
17,37	1,656	0,00	1,42	6,8	4,4
20,05	1,679	0,00	1,44	3,2	2,2
23,18	1,436	0,00	1,54	2,7	1,2

Amostra 91					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
10,37	1,358	0,00	0,00	26,4	2,2
13,13	1,466	0,00	0,31	23,5	3,2
15,14	1,656	0,36	0,83	11,8	6,0
18,03	1,628	0,45	1,07	11,8	7,6
21,36	1,377	0,55	1,59	11,8	2,2

Amostra 92					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
12,33	1,552	0,57	0,32	23,5	4,1
14,78	1,653	0,49	0,62	15,3	7,6
17,00	1,752	0,42	0,89	13,4	8,5
18,78	1,744	0,02	1,14	11,8	6,8
21,74	1,554	0,00	1,39	2,2	3,2

Amostra 93					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
17,34	1,340	1,74	0,24	24,2	1,2
18,93	1,374	0,84	0,54	19,0	1,9
21,77	1,481	0,44	0,80	9,3	5,2
25,55	1,444	0,12	1,16	5,2	5,9
28,06	1,342	0,08	1,40	3,6	1,9

Amostra 94					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
18,24	1,312	2,25	0,57	24,2	2,2
20,37	1,413	1,25	1,26	16,6	4,1
23,65	1,536	0,64	2,11	11,8	6,0
25,46	1,455	0,16	2,32	9,2	5,2
27,56	1,332	0,02	2,50	4,4	1,9

Amostra 95					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
10,34	1,713	0,00	0,55	9,3	1,2
12,80	1,780	0,00	0,60	10,7	4,1
14,87	1,792	0,00	0,65	5,0	4,4
16,49	1,768	0,00	0,80	2,7	2,7
18,77	1,712	0,00	0,88	2,2	1,2

Amostra 96					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
16,20	1,595	0,16	0,26	7,6	1,2
17,54	1,686	0,14	0,30	6,8	3,6
19,06	1,701	0,08	0,33	5,2	3,2
20,07	1,653	0,04	0,43	3,6	2,7
21,04	1,630	0,00	0,44	3,2	1,9

Amostra 97					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
5,52	1,606	0,00	0,15	24,2	1,2
8,26	1,791	0,00	0,21	21,2	5,2
10,29	1,881	0,00	0,34	13,8	7,6
12,78	1,865	0,00	0,36	6,8	5,2
14,17	1,616	0,00	0,37	2,2	2,7

Amostra 98					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,48	1,687	0,00	0,00	7,6	2,2
5,64	1,735	0,00	0,02	6,8	3,6
7,67	1,768	0,00	0,04	5,9	3,2
9,44	1,773	0,00	0,06	2,7	1,9
11,14	1,687	0,00	0,10	2,7	1,2

Amostra 99					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,28	1,590	0,30	0,06	37,8	1,2
9,17	1,687	0,04	0,17	39,3	2,7
11,44	1,779	0,00	0,40	5,0	3,2
13,58	1,799	0,00	0,48	4,4	1,9
16,59	1,582	0,00	0,51	4,4	1,2

Amostra 100					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,84	1,747	0,15	0,15	22,7	1,2
9,39	1,809	0,02	0,34	21,2	3,6
11,07	1,852	0,00	0,37	16,0	8,5
13,47	1,845	0,00	0,54	9,3	6,0
16,83	1,728	0,00	0,74	8,5	1,9

Amostra 101					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,94	1,451	0,36	0,00	36,4	4,1
15,45	1,712	0,16	0,04	22,7	11,0
17,46	1,771	0,12	0,29	12,2	10,1
18,15	1,739	0,04	0,71	8,5	9,3
20,29	1,534	0,00	0,74	7,6	3,6

ANEXO H

**RESUMO DAS PROPRIEDADES DOS SOLOS NA UMIDADE ÓTIMA
PARA A ENERGIA INTERMEDIÁRIA
E
RESULTADOS DOS ENSAIOS DE MINI-CBR, EXPANSÃO E CONTRAÇÃO
NA ENERGIA INTERMEDIÁRIA**

Resumo das propriedades dos solos na umidade ótima para a energia intermediária.

Amostra	Umidade Ótima (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediateo)	Mini-CBR (24h)
01	12,05	1,985	0,06	0,30	35,0	32,1
02	16,26	1,851	0,18	0,83	22,7	11,0
03	12,30	1,940	0,04	0,52	39,3	22,0
04	25,50	1,625	0,30	2,60	23,0	17,0
05	26,50	1,600	0,50	2,30	31,0	17,0
06	13,67	1,912	0,00	0,43	26,4	23,5
07	16,81	1,864	0,24	1,13	27,1	16,0
08	14,80	1,905	0,05	0,70	40,0	30,0
09	11,30	1,935	0,02	0,40	19,0	14,0
10	14,41	1,867	0,00	0,89	42,8	26,4
11	16,80	1,830	0,05	0,50	54,0	35,0
12	17,40	1,810	0,80	1,06	30,0	20,0
13	12,90	2,045	0,25	0,60	48,0	35,0
14	21,52	1,805	0,00	0,43	24,2	18,3
15	13,50	1,862	0,05	0,65	32,0	31,0
16	6,10	2,065	0,00	0,14	30,0	19,0
17	14,50	1,922	0,06	0,54	42,8	36,4
18	8,80	2,080	0,17	0,10	23,0	14,0
19	13,82	1,971	0,32	0,87	33,6	24,9
20	12,55	1,938	0,08	0,64	38,6	22,4
21	14,60	1,993	0,07	0,55	30,0	22,0
22	4,36	1,810	0,16	0,14	24,0	18,0
23	12,73	1,943	0,18	0,43	52,6	26,4
24	13,40	1,930	0,35	0,60	31,0	27,0
25	9,80	2,020	0,00	0,20	26,0	20,0
26	8,45	2,007	0,20	0,09	22,7	16,6
27	8,28	2,049	0,00	0,57	14,5	9,3
28	16,40	1,840	0,00	0,17	53,0	37,0
29	18,72	1,782	0,38	1,59	51,9	28,5
30	6,80	1,930	0,00	0,02	21,0	15,0
31	22,01	1,892	0,00	1,20	11,5	8,5
32	8,49	2,046	0,10	0,18	33,7	18,3
33	9,60	2,070	0,10	0,23	70,0	37,0
34	10,30	1,955	0,02	0,40	47,0	37,0
35	17,60	1,777	0,14	1,40	17,0	12,0
36	16,20	1,900	0,14	0,53	36,0	14,0
37	24,00	1,672	0,25	1,20	17,0	15,0
38	24,90	1,630	0,06	1,71	21,0	12,0
39	23,35	1,728	0,02	0,85	23,4	12,2
40	12,00	1,978	0,14	0,30	24,0	20,0

Resumo das propriedades dos solos na umidade ótima para a energia intermediária.

Amostra	Umidade Ótima (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
41	6,50	1,860	0,17	1,30	27,0	15,0
42	22,00	1,780	0,15	0,30	35,0	16,0
43	12,34	1,782	0,00	0,30	48,4	25,6
44	17,66	1,860	0,08	1,04	39,3	19,8
45	10,50	1,985	0,01	0,40	45,0	39,0
46	12,72	1,976	0,06	0,29	26,4	20,5
47	11,94	1,943	0,16	0,35	43,5	22,7
48	10,23	1,964	0,02	0,18	49,8	22,7
49	23,96	1,669	0,18	0,84	27,1	22,7
50	17,00	1,790	0,14	1,40	17,0	11,0
51	6,00	2,045	0,00	0,40	26,4	24,0
52	21,50	1,757	0,07	0,80	30,0	20,0
53	13,20	2,024	0,20	0,62	39,0	16,8
54	21,00	1,908	0,00	1,20	18,9	8,5
55	10,22	2,242	0,02	0,74	22,0	19,6
56	14,08	1,956	0,02	0,72	17,3	16,6
57	6,23	1,899	0,02	0,01	38,0	17,3
58	13,56	2,137	0,02	0,30	48,4	38,7
59	14,90	1,881	0,06	0,20	24,2	20,5
60	11,76	1,960	0,55	0,08	71,1	42,1
61	7,32	1,893	0,06	0,12	35,1	15,8
62	7,20	1,854	0,02	0,12	42,1	14,2
63	7,60	1,969	0,03	0,17	42,0	18,0
64	9,93	2,068	0,06	0,24	28,6	23,5
65	7,00	1,938	0,00	0,05	22,0	12,0
66	6,01	2,061	0,10	0,43	18,9	13,4
67	4,70	1,867	0,01	0,12	15,0	16,0
68	4,46	1,967	0,03	0,5	20,0	15,0
69	5,50	1,975	0,02	0,11	15,0	14,3
70	14,30	2,040	0,27	0,55	35,0	28,0
71	14,24	1,893	0,09	0,42	32,9	28,5
72	13,51	2,118	0,32	0,40	54,6	22,0
73	9,59	2,238	0,56	0,32	44,2	22,7
74	17,00	1,760	0,05	0,30	31,0	18,0
75	13,40	1,965	0,47	0,62	30,0	29,0
76	11,42	2,158	0,37	0,42	48,4	20,4
77	12,20	1,942	0,15	0,45	44,0	32,0
78	12,11	2,031	0,01	0,40	31,4	27,8
79	11,22	2,045	0,32	0,39	40,1	30,7
80	10,93	1,794	0,00	0,30	12,6	9,7

Resumo das propriedades dos solos na umidade ótima para a energia intermediária.

Amostra	Umidade Ótima (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
81	4,40	1,845	0,01	0,09	10,0	7,0
82	8,63	1,895	0,01	0,18	9,3	5,0
83	24,50	1,453	0,90	1,13	10,0	8,5
84	7,00	1,870	0,02	0,27	19,0	8,8
85	6,11	1,751	0,05	0,12	14,2	7,6
86	6,45	1,792	0,02	0,71	6,8	3,6
87	6,20	1,803	0,00	0,19	29,6	12,6
88	4,40	1,783	0,13	0,07	12,0	6,5
89	5,00	1,701	0,08	0,09	15,0	8,0
90	17,61	1,720	0,00	1,02	6,8	4,3
91	14,00	1,682	0,32	0,69	20,0	13,0
92	15,42	1,790	0,20	0,70	22,7	15,0
93	20,10	1,500	0,20	0,78	11,3	6,5
94	26,01	1,582	0,50	1,90	15,5	9,2
95	12,50	1,810	0,00	0,40	8,0	5,5
96	16,70	1,770	0,16	0,63	17,0	13,0
97	9,52	1,902	0,02	0,10	18,1	7,2
98	6,06	1,820	0,00	0,06	5,5	3,0
99	11,01	1,860	0,04	0,31	10,4	2,8
100	10,09	1,910	0,00	0,38	26,9	11,0
101	15,94	1,961	0,06	0,24	18,9	11,5

Resultados dos ensaios de Mini-CBR, Expansão e Contração na Energia Intermediária

Amostra 01					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,31	1,86	0,20	0,22	54,6	14,2
10,76	1,96	0,18	0,16	49,1	32,9
12,05	1,98	0,06	0,29	35,0	32,1
13,49	1,93	0,04	0,42	13,0	13,8
14,70	1,66	0,00	0,59	2,2	3,2
16,09	1,48	0,00	0,63	9,3	8,0

Amostra 02					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,53	1,56	1,13	0,09	58,1	4,0
13,58	1,69	0,50	0,51	47,0	9,3
14,87	1,81	0,28	0,77	44,2	15,8
16,26	1,85	0,17	0,83	22,7	16,0
18,93	1,78	0,00	1,08	13,0	7,6

Amostra 03					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,04	1,782	0,29	0,20	53,3	5,0
11,14	1,898	0,04	0,44	47,7	14,6
12,30	1,940	0,04	0,52	39,3	22,0
14,95	1,869	0,07	0,86	10,1	8,4
16,31	1,826	0,06	0,97	9,3	6,8

Amostra 04					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
20,48	1,485	2,59	1,10	39,3	9,3
23,86	1,612	0,69	2,30	22,4	15,8
26,85	1,620	0,13	2,69	22,0	15,0
29,35	1,568	0,17	2,88	12,2	9,3
31,59	1,520	0,54	3,41	7,6	6,0

Amostra 05					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
20,77	1,487	3,45	1,36	47,7	9,2
24,17	1,579	0,95	1,89	40,7	19,6
27,60	1,591	0,31	2,50	27,1	14,6
30,92	1,451	0,09	2,59	12,2	8,0
32,99	1,435	0,00	2,79	6,8	4,0

Amostra 06					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
9,89	1,822	0,14	0,32	38,6	12,6
12,37	1,887	0,02	0,32	25,6	25,6
13,67	1,912	0,00	0,43	26,4	23,5
15,23	1,883	0,00	0,57	19,0	13,0
16,59	1,845	0,00	0,77	6,8	7,6

Amostra 07					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,93	1,720	0,79	0,34	40,1	5,0
14,52	1,816	0,43	0,69	35,8	13,4
16,81	1,864	0,24	1,13	27,1	16,0
19,25	1,775	0,18	1,25	11,0	6,0
22,23	1,716	0,00	2,08	5,0	3,2

Amostra 08					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,70	1,789	0,18	0,50	49,1	6,8
14,33	1,896	0,06	0,73	44,2	27,1
15,96	1,888	0,04	0,84	28,5	25,6
16,64	1,866	0,02	0,98	24,9	19,0
17,46	1,843	0,00	1,06	17,5	12,6

Amostra 09					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
9,24	1,772	0,02	0,25	19,0	3,6
10,54	1,912	0,02	0,29	18,3	10,7
11,60	1,929	0,02	0,39	19,0	12,2
13,36	1,834	0,02	0,57	15,3	5,2
14,58	1,772	0,00	0,70	9,3	3,2

Amostra 10					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
10,31	1,550	0,21	0,03	62,2	4,1
12,21	1,798	0,04	0,56	49,1	14,2
14,41	1,867	0,00	0,89	42,8	26,4
16,11	1,826	0,00	0,96	24,9	17,5
17,93	1,777	0,00	1,04	13,8	9,2

Amostra 11					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
14,47	1,696	0,42	0,14	58,8	15,8
15,81	1,801	0,12	0,42	59,5	30,1
17,22	1,822	0,03	0,49	49,4	34,3
18,69	1,722	0,00	0,60	22,7	24,5
19,60	1,653	0,00	0,85	21,2	15,3

Amostra 12					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
15,39	1,682	1,88	0,69	43,5	15,8
16,58	1,764	1,34	0,98	49,1	24,9
17,66	1,798	0,72	1,08	24,9	17,3
19,50	1,616	0,03	1,13	13,0	10,3
20,52	1,467	0,11	1,18	9,3	8,0

Amostra 13					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
11,50	1,777	0,43	0,31	51,9	6,8
12,25	2,021	0,30	0,56	55,3	32,3
13,50	2,032	0,21	0,59	37,1	31,4
14,70	1,955	0,10	0,58	22,0	19,8
16,43	1,838	0,00	0,79	15,0	9,2

Amostra 14					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
19,52	1,719	0,02	0,10	25,6	5,2
20,60	1,766	0,00	0,20	13,8	9,3
21,52	1,805	0,00	0,43	24,2	18,3
22,31	1,750	0,00	0,80	17,2	12,6
23,02	1,703	0,00	1,11	10,1	8,4

Amostra 15					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
8,27	1,634	1,12	0,24	60,2	3,6
12,50	1,856	0,16	0,58	37,8	33,6
17,03	1,804	0,00	0,74	19,0	12,2
20,21	1,721	0,02	0,96	6,0	5,5
23,19	1,679	0,02	0,96	6,0	5,5

Amostra 16					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
4,46	1,805	0,26	0,10	47,0	6,8
5,83	2,055	0,02	0,12	32,1	16,8
7,15	2,013	0,00	0,17	29,3	18,3
8,11	1,953	0,00	0,23	33,7	8,4
9,51	1,869	0,00	0,34	24,2	3,6

Amostra 17					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
10,77	1,696	0,58	0,15	86,0	5,0
12,40	1,876	0,18	0,34	60,9	35,0
14,50	1,922	0,05	0,53	42,8	36,4
18,44	1,833	0,02	0,56	16,6	22,7
21,13	1,700	0,00	0,62	9,3	8,0

Amostra 18					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,36	1,799	0,42	0,04	20,4	3,2
7,13	1,957	0,32	0,06	24,9	6,8
8,37	2,068	0,22	0,08	30,1	13,4
9,19	2,061	0,10	0,12	15,8	11,8
10,26	1,834	0,06	0,19	9,9	8,5

Amostra 19					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,10	1,737	1,31	0,32	56,0	6,8
11,15	1,837	0,79	0,48	53,3	11,8
13,82	1,971	0,32	0,86	33,6	24,9
16,17	1,900	0,20	1,48	10,7	9,2
19,25	1,801	0,09	1,50	5,0	6,0

Amostra 20					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,11	1,779	0,31	0,22	54,0	5,9
11,30	1,892	0,10	0,46	47,0	15,0
12,55	1,938	0,08	0,64	38,6	22,4
15,01	1,870	0,05	0,88	11,0	9,2
16,48	1,823	0,04	0,95	8,5	7,6

Amostra 21					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,82	1,809	0,10	0,48	41,4	16,0
14,29	1,990	0,08	0,53	32,1	22,7
16,15	1,942	0,04	0,60	15,3	9,9
17,94	1,776	0,02	0,83	6,8	5,0

Amostra 22					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,00	1,755	0,21	0,05	37,3	2,2
4,36	1,810	0,14	0,13	26,4	9,3
6,13	1,790	0,10	0,16	21,2	10,1
7,21	1,770	0,09	0,21	23,5	9,3
8,26	1,736	0,08	0,26	15,0	8,4

Amostra 23					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,76	1,825	0,38	0,11	59,5	4,4
12,00	2,033	0,32	0,30	65,7	17,5
12,73	2,157	0,17	0,43	52,6	26,4
15,03	1,881	0,02	0,58	25,6	10,7
16,07	1,766	0,00	0,83	11,5	6,0

Amostra 24					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,23	1,757	1,38	0,32	55,3	1,2
12,26	2,164	0,49	0,58	36,4	15,3
14,69	1,902	0,21	0,64	51,9	26,4
15,82	1,857	0,08	0,70	5,9	1,2
17,11	1,763	0,04	1,12	5,0	1,2

Amostra 25					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,53	1,889	0,02	0,07	28,6	13,4
8,20	1,917	0,02	0,10	37,1	18,9
9,55	2,013	0,00	0,19	30,0	20,4
10,41	1,999	0,00	0,20	21,2	20,5
11,63	1,913	0,00	0,20	9,3	19,8

Amostra 26					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,48	1,888	0,32	0,07	34,3	16,8
7,70	1,903	0,21	0,07	25,7	17,3
9,42	1,989	0,19	0,09	22,7	16,6
10,62	1,917	0,16	0,10	19,6	13,0
11,63	1,897	0,10	0,10	10,7	8,5

Amostra 27					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,00	1,885	0,14	0,06	27,1	5,2
6,79	1,977	0,10	0,32	29,3	11,8
7,39	1,999	0,04	0,48	27,1	23,4
8,28	2,049	0,00	0,57	9,3	14,5
8,98	2,020	0,00	0,77	6,8	5,0

Amostra 28					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
14,23	1,716	0,00	0,02	71,8	26,4
16,21	1,840	0,00	0,16	53,3	37,1
18,12	1,787	0,02	0,27	51,9	24,2
19,24	1,737	0,00	0,43	24,2	13,0

Amostra 29					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
15,29	1,579	2,40	1,24	58,8	11,5
16,78	1,679	1,28	1,40	54,0	18,9
18,72	1,782	0,37	1,58	51,9	28,5
20,25	1,739	0,06	1,91	24,9	14,5
21,04	1,701	0,04	1,90	25,7	14,2

Amostra 30					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
3,70	1,858	0,00	0,02	48,5	6,0
5,47	1,919	0,00	0,02	30,0	6,0
7,21	1,928	0,00	0,02	21,2	18,1
8,40	1,885	0,00	0,02	18,9	10,7
10,17	1,850	0,00	0,06	20,4	6,8

Amostra 31					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
18,32	1,559	0,04	0,99	12,2	3,6
20,62	1,797	0,02	1,17	16,8	12,6
22,01	1,892	0,00	1,19	11,5	8,5
23,72	1,712	0,00	1,20	6,0	4,1
25,08	1,555	0,00	1,31	3,6	4,1

Amostra 32					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
5,45	1,947	0,18	0,08	53,3	4,4
6,48	1,990	0,13	0,14	38,6	8,4
8,49	2,046	0,10	0,18	33,7	18,3
9,64	2,000	0,06	0,20	27,9	8,5
11,03	1,944	0,06	0,22	17,3	6,0

Amostra 33					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
7,32	1,929	0,19	0,02	72,5	8,5
8,70	2,053	0,11	0,15	83,3	11,8
10,38	2,064	0,10	0,28	54,0	40,7
12,19	2,008	0,06	0,44	13,8	11,0
15,83	1,870	0,04	0,73	2,2	1,2

Amostra 34					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
7,73	1,736	0,13	0,04	54,0	10,1
8,20	1,821	0,06	0,12	62,0	11,8
9,80	1,945	0,02	0,34	53,3	31,5
10,73	1,944	0,00	0,42	38,0	36,4
12,09	1,725	0,00	0,73	2,2	9,3

Amostra 35					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
15,08	1,637	0,48	0,38	40,7	4,1
16,25	1,695	0,20	0,78	36,4	12,6
17,01	1,765	0,16	0,91	20,4	15,3
18,14	1,768	0,11	1,59	14,5	8,4
19,00	1,659	0,09	1,66	7,6	4,4

Amostra 36					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
13,80	1,724	0,28	0,47	26,4	20,5
15,94	1,896	0,16	0,46	35,7	25,6
17,43	1,851	0,04	1,00	32,1	11,5
19,43	1,770	0,00	1,04	6,0	5,9
20,42	1,717	0,00	1,17	3,2	5,2

Amostra 37					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
19,80	1,511	0,43	0,29	12,6	9,3
21,94	1,631	0,38	0,93	15,3	14,2
23,02	1,668	0,28	1,12	16,0	14,2
25,52	1,656	0,21	1,31	14,5	13,4
27,98	1,531	0,15	1,39	6,0	8,4

Amostra 38					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
19,71	1,483	0,11	1,03	35,0	5,2
21,64	1,530	0,10	1,26	29,3	7,6
23,54	1,597	0,07	1,51	27,8	14,2
25,19	1,626	0,05	1,79	19,0	11,0
27,08	1,486	0,02	1,85	8,4	7,6

Amostra 39					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
17,31	1,431	0,099	0,528	33,7	5,2
19,80	1,655	0,020	0,609	27,1	14,2
23,35	1,728	0,020	0,850	23,4	12,2
25,70	1,661	0,000	1,293	8,5	6,8
26,33	1,461	0,000	1,426	6,0	6,8

Amostra 40					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
9,62	1,915	0,20	0,22	46,4	16,0
10,91	1,966	0,13	0,18	40,8	23,5
12,43	1,977	0,12	0,34	31,5	19,0
13,27	1,940	0,02	0,58	29,3	16,6
14,02	1,916	0,00	0,70	22,7	13,8

Amostra 41					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,05	1,752	0,31	0,00	30,8	5,2
4,20	1,786	0,29	0,06	28,6	16,0
5,46	1,838	0,27	1,10	29,3	16,6
6,88	1,852	0,14	1,30	21,2	11,0
8,25	1,740	0,08	1,46	3,2	2,2

Amostra 42					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
17,97	1,537	0,38	0,12	48,4	4,4
21,48	1,769	0,18	0,28	42,8	16,0
23,82	1,724	0,12	0,29	11,8	6,0
25,37	1,592	0,06	0,39	6,8	5,2
26,49	1,558	0,00	0,48	6,0	4,1

Amostra 43					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
9,18	1,716	0,06	0,12	54,6	10,1
10,89	1,763	0,02	0,28	54,0	17,5
12,34	1,782	0,00	0,29	48,4	25,6
13,70	1,740	0,0	0,40	42,1	24,2
13,89	1,734	0,00	0,48	32,1	16,8

Amostra 44					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
14,50	1,622	0,12	0,41	9,3	7,6
16,47	1,785	0,10	0,84	15,3	19,8
17,66	1,860	0,08	1,04	39,3	19,8
19,14	1,791	0,07	1,07	32,3	10,7
20,74	1,759	0,06	1,11	9,3	6,8

Amostra 45					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
6,62	1,681	0,12	0,04	54,6	7,6
8,20	1,821	0,06	0,12	76,5	8,5
9,80	1,945	0,02	0,34	53,3	11,5
10,73	1,976	0,00	0,42	38,0	36,4
12,09	1,725	0,00	0,73	2,2	1,2

Amostra 46					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
9,46	1,838	0,18	0,02	54,6	3,2
10,72	1,892	0,08	0,16	51,2	9,3
12,72	1,976	0,06	0,28	26,4	20,5
14,39	1,894	0,04	0,43	15,3	11,5
15,47	1,847	0,00	1,08	10,1	7,6

Amostra 47					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
9,54	1,654	0,50	0,31	19,8	3,2
10,82	1,878	0,22	0,32	53,3	24,9
11,94	1,943	0,16	0,34	43,5	22,7
13,29	1,907	0,09	0,70	18,3	16,0
15,09	1,670	0,06	0,88	11,0	7,6

Amostra 48					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
7,26	1,864	0,06	0,10	54,6	6,0
9,12	1,953	0,04	0,13	52,6	15,8
10,23	1,964	0,02	0,17	49,8	22,7
11,26	1,953	0,02	0,24	15,3	11,8
13,73	1,872	0,00	0,31	10,1	7,6

Amostra 49					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
19,04	1,481	0,29	0,53	33,7	5,2
22,08	1,641	0,21	0,63	27,9	24,9
23,96	1,669	0,17	0,83	27,1	22,7
25,91	1,620	0,09	1,28	16,8	15,3
27,15	1,510	0,02	1,38	12,2	9,9

Amostra 50					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
15,08	1,637	0,48	0,38	40,7	4,1
15,82	1,701	0,20	0,78	36,4	12,6
16,42	1,774	0,16	0,91	20,4	15,3
17,32	1,780	0,11	1,59	14,5	8,4
17,90	1,642	0,09	1,66	7,6	4,4

Amostra 51					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
2,35	1,956	0,14	0,32	27,9	12,6
4,58	2,028	0,02	0,32	25,6	25,6
6,46	2,042	0,00	0,43	26,4	23,5
8,50	2,000	0,00	0,57	19,0	13,0
10,45	1,948	0,00	0,77	6,8	7,6

Amostra 52					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
18,43	1,605	0,33	0,43	54,6	7,6
20,26	1,738	0,16	0,67	51,2	19,8
22,09	1,753	0,04	0,86	23,5	16,6
24,82	1,682	0,00	1,18	9,3	5,9
26,47	1,625	0,00	2,08	5,0	5,2

Amostra 53					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediato)	Mini-CBR (24h)
11,30	1,829	0,39	0,53	39,4	5,2
12,91	2,018	0,20	0,61	40,0	16,8
14,41	1,962	0,19	0,82	23,4	7,6
15,93	1,883	0,07	1,43	5,2	4,4
17,52	1,827	0,06	1,73	3,2	1,9

Amostra 54					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
18,32	1,559	0,04	0,99	20,4	3,6
19,54	1,814	0,02	1,17	20,4	12,6
21,00	1,908	0,00	1,19	18,9	8,5
22,53	1,729	0,00	1,20	6,0	4,1
23,54	1,574	0,00	1,31	3,6	2,2

Amostra 55					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,01	1,870	0,06	0,34	16,8	11,0
8,29	1,983	0,04	0,63	25,7	17,3
10,22	2,242	0,02	0,73	22,0	19,6
11,62	2,023	0,00	1,12	13,4	14,5
13,13	1,881	0,00	1,09	8,5	7,6

Amostra 56					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,04	1,790	0,06	0,34	38,7	3,2
12,70	1,917	0,04	0,62	37,1	18,3
14,08	1,956	0,02	0,71	17,3	16,6
16,13	1,866	0,00	1,08	8,5	8,5
18,09	1,779	0,00	1,10	4,1	3,6

Amostra 57					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,54	1,755	0,12	0,02	45,0	7,6
5,25	1,863	0,06	0,08	45,6	15,3
6,23	1,899	0,02	0,09	38,0	17,3
8,22	1,812	0,00	0,12	26,4	9,3
9,74	1,748	0,00	0,20	13,0	6,8

Amostra 58					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,01	1,680	0,06	0,05	81,3	9,3
12,58	1,901	0,04	0,16	62,9	38,6
13,56	2,137	0,02	0,29	48,4	38,7
14,51	1,784	0,02	0,31	30,7	23,5
15,77	1,622	0,00	0,34	18,3	4,4

Amostra 59					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,35	1,641	0,34	0,16	62,2	6,8
13,03	1,787	0,16	0,16	40,7	27,9
14,90	1,881	0,06	0,20	24,2	20,5
17,01	1,793	0,00	0,20	16,6	8,4
19,84	1,627	0,00	0,26	15,8	4,4

Amostra 60					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,21	1,700	1,14	0,04	91,3	5,2
10,24	1,887	0,85	0,04	73,1	26,4
11,76	1,960	0,54	0,08	71,1	42,1
13,37	1,864	0,20	0,11	30,7	22,0
14,59	1,732	0,19	0,13	17,5	14,5

Amostra 61					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,59	1,737	0,12	0,02	45,0	7,6
6,13	1,848	0,08	0,08	45,6	15,3
7,32	1,893	0,06	0,11	35,1	15,8
8,22	1,812	0,00	0,12	26,4	9,3
9,74	1,748	0,00	0,20	13,0	6,8

Amostra 62					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,73	1,699	0,08	0,08	65,0	6,8
5,82	1,816	0,04	0,10	46,3	11,8
7,20	1,854	0,02	0,12	42,1	14,2
8,82	1,884	0,00	0,14	32,9	7,6
10,53	1,822	0,00	0,16	18,3	4,4

Amostra 63					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,64	1,778	0,12	0,10	60,2	2,2
6,59	1,923	0,06	0,16	43,5	8,5
8,07	1,961	0,02	0,19	39,3	21,2
9,68	1,831	0,00	0,19	19,8	9,3
10,53	1,764	0,00	0,26	15,8	4,4

Amostra 64					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,63	1,767	0,34	0,16	60,9	10,1
8,84	2,011	0,12	0,18	40,7	27,9
9,93	2,068	0,06	0,23	28,6	23,4
11,94	1,992	0,00	0,25	11,5	10,7
13,37	1,752	0,00	0,26	10,1	4,4

Amostra 65					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,11	1,719	0,03	0,02	25,6	3,6
6,00	1,916	0,00	0,03	28,6	6,8
8,05	1,926	0,00	0,05	18,9	18,1
8,92	1,862	0,00	0,06	18,1	12,6
10,28	1,739	0,00	0,16	17,3	3,6

Amostra 66					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,33	1,804	0,60	0,12	21,2	4,4
5,16	2,008	0,09	0,31	19,6	9,3
6,01	2,061	0,10	0,42	18,9	13,4
6,91	1,954	0,08	0,73	8,5	11,0
7,59	1,836	0,00	0,77	6,8	5,0

Amostra 67					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,54	1,810	0,09	0,04	44,2	5,2
3,37	1,860	0,04	0,04	29,3	8,5
4,26	1,866	0,02	0,09	18,3	13,4
5,21	1,867	0,00	0,11	15,0	16,0
6,00	1,862	0,00	0,13	17,3	8,5

Amostra 68					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,50	1,858	0,14	0,06	27,1	5,2
3,53	1,943	0,03	0,31	29,3	7,6
4,08	1,966	0,03	0,47	27,1	16,0
4,94	1,953	0,00	0,56	9,3	9,3
5,72	1,868	0,00	0,77	6,8	5,0

Amostra 69					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,57	1,800	0,05	0,03	49,1	2,7
3,76	1,877	0,03	0,07	38,7	6,0
5,32	1,973	0,02	0,10	16,0	14,2
6,65	1,934	0,00	0,14	13,4	7,6
8,06	1,774	0,00	0,16	17,3	3,6

Amostra 70					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,11	1,658	0,32	0,28	59,5	9,3
13,32	2,003	0,30	0,46	53,3	29,3
15,57	2,006	0,25	0,64	18,3	17,3
17,12	1,807	0,23	1,07	13,0	7,6
17,91	1,702	0,11	1,09	8,5	7,6

Amostra 71					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,68	1,691	0,59	0,12	78,6	9,3
12,43	1,856	0,10	0,32	67,0	25,6
14,24	1,893	0,09	0,41	32,9	28,5
15,34	1,866	0,00	0,70	19,8	16,8
17,41	1,682	0,00	0,77	6,8	5,0

Amostra 72					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,14	1,737	1,42	0,28	60,2	7,6
12,01	1,937	1,14	0,35	63,4	11,5
13,51	2,118	0,32	0,39	54,6	22,0
14,20	2,033	0,05	0,51	27,8	19,0
15,16	1,743	0,00	1,09	8,5	7,6

Amostra 73					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,85	1,731	0,72	0,16	45,6	5,9
7,58	1,955	0,61	0,27	62,2	17,5
9,59	2,238	0,56	0,31	44,2	22,7
11,37	1,977	0,24	0,46	22,7	16,8
13,30	1,878	0,11	1,09	8,5	7,6

Amostra 74					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
14,39	1,586	0,27	0,15	45,6	5,9
15,79	1,748	0,11	0,27	56,0	16,8
18,57	1,745	0,00	0,32	14,5	13,8
20,67	1,684	0,00	0,45	9,3	4,1
22,53	1,571	0,00	1,09	8,5	1,2

Amostra 75					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
11,04	1,660	0,66	0,16	49,1	9,3
13,01	1,955	0,54	0,46	37,8	32,1
14,36	1,901	0,33	1,05	16,0	13,0
16,70	1,802	0,23	1,08	9,2	8,4
18,12	1,776	0,11	1,09	8,5	7,6

Amostra 76					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,33	1,633	0,41	0,19	70,4	5,0
9,04	1,763	0,39	0,40	53,3	15,3
11,42	2,158	0,36	0,42	48,4	20,4
13,12	1,758	0,34	0,44	41,4	13,8
15,18	1,619	0,11	0,49	8,5	7,6

Amostra 77					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,19	1,627	0,20	0,19	40,7	3,6
11,34	1,917	0,18	0,45	49,1	25,6
13,00	1,922	0,11	0,46	35,0	28,5
14,00	1,822	0,10	0,58	11,5	9,9
14,67	1,722	0,00	0,77	6,8	5,0

Amostra 78					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,97	1,757	0,16	0,28	41,4	5,9
10,33	1,970	0,10	0,36	33,0	31,4
12,11	2,031	0,09	0,39	31,4	27,8
14,02	1,916	0,06	0,51	18,9	9,3
15,61	1,736	0,00	1,09	17,3	7,6

Amostra 79					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,59	1,735	0,44	0,28	71,1	2,7
10,10	2,001	0,34	0,36	50,5	10,1
11,22	2,045	0,31	0,39	40,1	30,7
12,34	1,964	0,06	0,52	34,3	30,7
15,16	1,743	0,00	1,09	17,3	7,6

Amostra 80					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
7,19	1,718	0,14	0,06	38,6	5,2
9,61	1,778	0,02	0,24	25,6	10,1
10,93	1,794	0,00	0,29	12,6	9,2
12,47	1,766	0,00	0,57	10,1	5,0
14,02	1,744	0,00	0,77	6,8	3,2

Amostra 81					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,06	1,781	0,11	0,00	15,3	2,2
3,00	1,836	0,04	0,04	20,4	4,4
4,20	1,844	0,00	0,10	8,5	7,6
5,13	1,825	0,00	0,10	7,6	6,0
6,24	1,775	0,00	0,12	2,7	3,2

Amostra 82					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
5,63	1,835	0,04	0,00	18,3	2,2
6,76	1,864	0,02	0,09	23,5	7,6
8,63	1,895	0,01	0,18	9,3	5,0
9,91	1,882	0,00	0,26	5,2	2,2
11,08	1,837	0,00	0,32	4,4	1,2

Amostra 83					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
20,13	1,309	1,74	0,75	24,2	1,2
22,00	1,383	1,16	0,84	19,0	1,9
24,20	1,452	0,90	1,10	11,0	8,1
25,55	1,423	0,79	1,16	5,2	5,9
28,06	1,342	0,20	1,40	3,6	1,9

Amostra 84					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
4,87	1,741	0,06	0,22	34,4	3,6
5,61	1,788	0,02	0,23	56,0	6,8
6,60	1,868	0,02	0,27	20,4	9,3
8,84	1,847	0,00	0,28	15,8	5,2
9,86	1,784	0,00	0,48	11,0	2,7

Amostra 85					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,74	1,633	0,22	0,04	24,2	1,2
4,61	1,695	0,11	0,09	16,6	5,2
6,11	1,751	0,05	0,11	14,2	7,6
8,25	1,712	0,00	0,19	6,8	1,9
9,98	1,634	0,00	0,22	5,9	1,2

Amostra 86					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,29	1,698	0,11	0,31	21,2	1,2
3,56	1,709	0,07	0,57	36,4	3,6
5,33	1,743	0,04	0,65	9,9	6,0
6,45	1,792	0,02	0,70	6,8	3,6
7,47	1,701	0,00	1,12	5,0	1,2

Amostra 87					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,38	1,672	0,07	0,07	91,3	3,6
5,45	1,752	0,06	0,10	53,3	6,8
6,20	1,803	0,00	0,19	29,6	12,6
8,03	1,769	0,00	0,24	22,0	7,6
9,24	1,689	0,00	0,39	22,7	6,8

Amostra 88					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,10	1,681	0,04	0,00	17,5	3,6
3,08	1,762	0,02	0,00	15,8	6,8
4,11	1,780	0,00	0,12	10,1	6,0
5,12	1,726	0,00	0,20	9,3	5,0
5,69	1,698	0,00	0,22	9,3	4,4

Amostra 89					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
3,80	1,446	0,12	0,02	28,6	4,1
4,49	1,606	0,09	0,05	24,2	6,8
5,00	1,701	0,08	0,09	15,0	8,0
5,34	1,612	0,03	0,11	8,5	6,8
5,98	1,459	0,00	0,17	6,8	3,6

Amostra 90					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,33	1,552	0,04	0,67	17,3	1,9
14,78	1,653	0,02	0,90	15,3	4,1
17,61	1,720	0,00	1,01	6,8	4,3
18,78	1,686	0,00	1,14	6,0	3,6
21,74	1,555	0,00	1,39	6,0	1,9

Amostra 91					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
8,95	1,481	0,59	0,17	26,4	1,2
11,13	1,570	0,42	0,44	26,4	5,9
12,97	1,666	0,40	0,58	23,4	17,3
15,01	1,670	0,23	0,75	16,6	7,6
17,46	1,517	0,17	0,88	8,5	5,2

Amostra 92					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
10,75	1,572	0,42	0,37	46,3	3,6
12,48	1,684	0,36	0,56	26,4	10,7
15,42	1,790	0,20	0,70	22,7	15,0
18,20	1,647	0,16	0,74	15,3	5,2
19,18	1,613	0,12	0,84	11,5	2,2

Amostra 93					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
17,70	1,421	0,44	0,56	17,3	2,7
19,04	1,472	0,31	0,61	21,2	6,0
20,10	1,500	0,20	0,78	11,3	6,5
22,03	1,458	0,18	0,80	6,8	3,3
22,96	1,430	0,10	0,82	5,2	2,2

Amostra 94					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
18,22	1,391	0,85	1,50	21,2	2,2
22,58	1,498	0,59	1,68	21,2	6,8
26,01	1,582	0,50	1,90	15,5	9,2
27,57	1,484	0,40	2,02	6,0	3,6
30,29	1,374	0,33	2,21	4,4	2,2

Amostra 95					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,84	1,718	0,13	0,15	22,7	1,2
9,39	1,771	0,02	0,24	21,2	3,6
11,07	1,802	0,00	0,27	16,0	7,6
13,47	1,806	0,00	0,49	5,9	4,1
16,83	1,728	0,00	0,74	5,0	1,9

Amostra 96					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
15,08	1,637	0,50	0,32	40,7	4,1
15,82	1,701	0,30	0,38	36,4	12,6
16,42	1,765	0,22	0,51	20,4	15,3
17,32	1,750	0,13	0,78	14,5	8,4
17,90	1,642	0,11	0,97	7,6	4,4

Amostra 97					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,05	1,813	0,08	0,04	38,7	1,9
7,93	1,876	0,06	0,08	24,2	6,0
9,52	1,902	0,02	0,10	18,1	7,2
10,46	1,882	0,02	0,13	6,0	4,4
12,25	1,820	0,00	0,14	3,6	2,2

Amostra 98					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
2,74	1,688	0,22	0,02	24,2	1,2
4,61	1,760	0,11	0,04	6,8	3,6
6,06	1,820	0,00	0,06	5,5	3,0
8,25	1,771	0,00	0,08	5,2	1,9
9,98	1,695	0,00	0,10	5,2	1,2

Amostra 99					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,46	1,516	0,09	0,20	19,0	1,4
10,02	1,796	0,06	0,23	15,0	2,7
11,01	1,860	0,04	0,31	10,4	2,8
13,55	1,698	0,02	0,39	7,6	1,2
15,05	1,503	0,00	0,49	7,6	1,2

Amostra 100					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
6,75	1,856	0,04	0,22	31,4	2,2
8,15	1,870	0,02	0,29	28,6	7,6
10,09	1,910	0,00	0,37	26,9	11,0
11,69	1,891	0,00	0,38	14,2	6,8
13,40	1,872	0,00	0,46	11,0	2,7

Amostra 101					
Umidade (%)	Massa específica seca máxima (g/cm ³)	Expansão (%)	Contração (%)	Mini-CBR (imediate)	Mini-CBR (24h)
12,07	1,682	0,20	0,16	74,5	2,7
14,28	1,915	0,12	0,18	30,1	5,0
15,94	1,961	0,06	0,23	18,9	11,5
17,88	1,892	0,00	0,25	10,1	19,0
19,49	1,662	0,00	0,26	10,1	4,4

ANEXO I

**VERIFICAÇÃO DA CONCORDÂNCIA ENTRE RESULTADOS PREVISTOS
PELA CLASSIFICAÇÃO MCT E OBTIDOS EM LABORATÓRIO**

Verificação da concordância entre resultados previstos pela Classificação MCT e obtidos em laboratório, para as amostras estudadas.

Amostra	Propriedades Classe MCT	Mini-CBR - Hm (%)			Mini-CBR - 24 h (%)			Expansão (%)			Contração (%)		
		Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância
1	LA	>12	22.0	sim	12 a 30	16.8	sim	< 0,5	0,00	sim	0 a 3	0,50	sim
2	LG	12 a 30	16.8	sim	12 a 30	9.9	não	< 0,5	0,00	sim	> 0,5	1,09	sim
3	LA	>12	14.2	sim	12 a 30	12.2	sim	< 0,5	0,10	sim	0 a 3	0,86	sim
4	LG	12 a 30	13.8	sim	12 a 30	9.2	não	< 0,5	0,28	sim	> 0,5	1,27	sim
5	LG	12 a 30	12.6	sim	12 a 30	9.3	não	< 0,5	0,18	sim	> 0,5	1,83	sim
6	NA	12 a 30	12.0	sim	4 a 30	7.0	sim	< 0,5	0,00	sim	0 a 3	0,60	sim
7	LG	12 a 30	9.3	sim	12 a 30	6.8	não	< 0,5	0,20	sim	> 0,5	0,77	sim
8	LG	12 a 30	31.0	sim	12 a 30	18.0	sim	< 0,5	0,00	sim	> 0,5	0,70	sim
9	LA	>12	11.0	não	12 a 30	7.6	não	< 0,5	0,00	sim	0 a 3	1,13	sim
10	LG	12 a 30	22.0	sim	12 a 30	9.3	não	< 0,5	0,08	sim	> 0,5	0,97	sim
11	NA	12 a 30	20.0	sim	4 a 30	11,2	sim	< 0,5	0,00	sim	0 a 3	0,61	sim
12	LA	>12	16.9	sim	12 a 30	12.2	sim	< 0,5	0,08	sim	0 a 3	1,06	sim
13	LG	12 a 30	21.2	sim	12 a 30	19,8	sim	< 0,5	0,00	sim	> 0,5	0,82	sim
14	LG	12 a 30	11.5	não	12 a 30	9.5	não	< 0,5	0,17	sim	> 0,5	0,75	sim
15	LG	12 a 30	14.5	sim	12 a 30	10,0	não	< 0,5	0,00	sim	> 0,5	0,65	sim
16	NA	4 a 30	14.0	sim	4 a 30	9,5	não	< 0,5	0,02	sim	< 0,5	0,70	não
17	LG	12 a 30	16.0	sim	12 a 30	6.0	não	< 0,5	0,04	sim	> 0,5	0,65	sim
18	LA	>12	17.0	sim	12 a 30	10,2	não	< 0,5	0,24	sim	0 a 3	0,16	sim
19	NA	12 a 30	10.7	não	4 a 30	9,3	sim	< 0,5	0,08	sim	0 a 3	0,80	sim
20	LA	>12	13.7	sim	12 a 30	13,0	sim	< 0,5	0,11	sim	0 a 3	0,85	sim
21	LG	12 a 30	15.0	sim	12 a 30	9.2	não	< 0,5	0,06	sim	> 0,5	0,89	sim
22	NA	4 a 30	11.0	sim	4 a 30	7.0	sim	< 0,5	0,03	sim	< 0,5	0,25	sim
23	NG	12 a 30	8.5	não	12 a 30	6.0	não	> 0,5	0,36	não	> 0,5	0,59	sim
24	LG	12 a 30	18.3	sim	12 a 30	6.8	não	< 0,5	0,12	sim	> 0,5	0,60	sim
25	LA	12 a 30	14.2	sim	12 a 30	4.4	não	< 0,5	0,22	sim	< 0,5	0,39	sim
26	LA	12 a 30	12.0	sim	12 a 30	8.5	não	< 0,5	0,01	sim	< 0,5	0,10	sim
27	NA	4 a 30	16.0	sim	4 a 30	5.0	sim	< 0,5	0,04	sim	< 0,5	0,08	sim

Verificação da concordância entre resultados previstos pela Classificação MCT e obtidos em laboratório, para as amostras estudadas.

Amostra	Propriedades Classe MCT	Mini-CBR - Hm (%)			Mini-CBR - 24 h (%)			Expansão (%)			Contração (%)		
		Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância
28	LG	12 a 30	24.2	sim	12 a 30	21.2	sim	< 0,5	0,08	sim	> 0,5	0,22	não
29	NG	12 a 30	18.3	sim	12 a 30	11.0	sim	> 0,5	0,04	não	> 0,5	2,22	sim
30	NA	4 a 30	14.0	sim	4 a 30	9.7	sim	< 0,5	0,08	sim	< 0,5	0,03	sim
31	NG	12 a 30	11.0	não	12 a 30	7.6	não	> 0,5	0,04	não	> 0,5	1,26	sim
32	NA	4 a 30	30.0	sim	4 a 30	13.4	sim	< 0,5	0,08	sim	< 0,5	0,12	sim
33	LA	>12	37.1	sim	12 a 30	22.7	sim	< 0,5	0,52	não	0 a 3	0,41	sim
34	LA	>12	16.0	sim	12 a 30	9.0	não	< 0,5	0,08	sim	0 a 3	0,09	sim
35	LG	12 a 30	6.0	não	12 a 30	4.2	não	< 0,5	0,13	sim	> 0,5	1,05	sim
36	LG	12 a 30	18.0	sim	12 a 30	14.0	sim	< 0,5	0,01	sim	> 0,5	0,93	sim
37	LG	12 a 30	9.0	não	12 a 30	7.0	não	< 0,5	0,15	sim	> 0,5	1,07	sim
38	LG	12 a 30	8.0	não	12 a 30	5.5	não	< 0,5	0,16	sim	> 0,5	1,05	sim
39	LG	12 a 30	7.4	não	12 a 30	4.0	não	< 0,5	0,20	sim	> 0,5	1,19	sim
40	LA	>12	13.6	sim	12 a 30	9.0	não	< 0,5	0,17	sim	0 a 3	0,55	sim
41	NA	12 a 30	15.0	sim	4 a 30	6.8	sim	< 0,5	0,64	não	0 a 3	0,28	sim
42	LG	12 a 30	20.0	sim	12 a 30	7.5	não	< 0,5	0,26	sim	> 0,5	0,56	sim
43	NS	4 a 30	12.6	sim	0 a 12	10.1	sim	> 3	0,10	não	0,5 a 3	0,58	sim
44	LG	12 a 30	13.0	sim	12 a 30	9.0	não	< 0,5	0,20	sim	> 0,5	0,40	não
45	LA	>12	19.0	sim	12 a 30	11.0	não	< 0,5	0,14	sim	0 a 3	0,30	sim
46	LG	12 a 30	16.0	sim	12 a 30	11.0	não	< 0,5	0,10	sim	> 0,5	0,45	não
47	LA	>12	14.0	sim	12 a 30	9.0	não	< 0,5	0,07	sim	0 a 3	0,58	sim
48	LA	>12	19.6	sim	12 a 30	16.0	sim	< 0,5	0,00	sim	0 a 3	0,31	sim
49	LG	12 a 30	9.6	não	12 a 30	6.0	não	< 0,5	0,00	sim	> 0,5	0,85	sim
50	LG	12 a 30	6.5	não	12 a 30	4.1	não	< 0,5	0,13	sim	> 0,5	1,07	sim
51	NA	12 a 30	13.4	sim	4 a 30	9.9	sim	< 0,5	0,08	sim	0 a 3	0,12	sim
52	LG	12 a 30	15.8	sim	12 a 30	10.7	não	< 0,5	0,12	sim	> 0,5	1,82	sim
53	LG	12 a 30	11.0	não	12 a 30	8.0	não	< 0,5	0,14	sim	> 0,5	0,95	sim
54	LG	12 a 30	13.4	sim	12 a 30	7.6	não	< 0,5	0,04	sim	> 0,5	1,26	sim

Verificação da concordância entre resultados previstos pela Classificação MCT e obtidos em laboratório, para as amostras estudadas.

Amostra	Propriedades Classe MCT	Mini-CBR - Hm (%)			Mini-CBR - 24 h (%)			Expansão (%)			Contração (%)		
		Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância
55	NA	12 a 30	13.0	sim	4 a 30	10.0	sim	< 0,5	0.10	sim	0 a 3	0.62	sim
56	LA	>12	11.0	não	12 a 30	8.0	não	< 0,5	0.05	sim	0 a 3	0.60	sim
57	LA	>12	18.0	sim	12 a 30	10.0	não	< 0,5	0.07	sim	0 a 3	0.07	sim
58	LG	12 a 30	20.5	sim	12 a 30	14.5	sim	< 0,5	0.24	sim	> 0,5	0.08	não
59	LA	>12	12.0	sim	12 a 30	7.0	não	< 0,5	0.04	sim	0 a 3	0.40	sim
60	LG	12 a 30	26.4	sim	12 a 30	11.8	não	< 0,5	0.09	sim	> 0,5	0.07	não
61	LA	>12	18.0	sim	12 a 30	10.0	não	< 0,5	0.07	sim	0 a 3	0.80	sim
62	LA	>12	17.5	sim	12 a 30	9.3	não	< 0,5	0.02	sim	0 a 3	0.12	sim
63	LA	>12	19.0	sim	12 a 30	14.0	sim	< 0,5	0.05	sim	0 a 3	0.08	sim
64	LA	>12	20.0	sim	12 a 30	14.5	sim	< 0,5	0.12	sim	0 a 3	0.30	sim
65	NA	4 a 30	17.0	sim	4 a 30	6.5	sim	< 0,5	0.00	sim	< 0,5	0.20	sim
66	NA	4 a 30	7.8	sim	4 a 30	5.2	sim	< 0,5	0.01	sim	< 0,5	0.14	sim
67	NA	4 a 30	12.6	sim	4 a 30	7.6	sim	< 0,5	0.00	sim	< 0,5	0.12	sim
68	NA	4 a 30	7.5	não	4 a 30	6.0	sim	< 0,5	0.06	sim	< 0,5	0.12	sim
69	NA	4 a 30	12.2	sim	4 a 30	9.5	sim	< 0,5	0.00	sim	< 0,5	0.14	sim
70	NA	4 a 30	16.0	sim	4 a 30	12.0	sim	< 0,5	0.03	sim	< 0,5	0.26	sim
71	LA	>12	25.0	sim	12 a 30	15.0	sim	< 0,5	0.00	sim	0 a 3	0.94	sim
72	LG	12 a 30	16.0	sim	12 a 30	11.5	não	< 0,5	0.00	sim	> 0,5	0.37	não
73	LA	>12	19.0	sim	12 a 30	11.0	não	< 0,5	0.14	sim	0 a 3	0.35	sim
74	LG	12 a 30	7.6	não	12 a 30	5.3	não	< 0,5	0.00	sim	> 0,5	0.54	sim
75	LG	12 a 30	14.2	sim	12 a 30	9.3	não	< 0,5	0.12	sim	> 0,5	0.96	sim
76	LG	12 a 30	12.6	sim	12 a 30	9.3	não	< 0,5	0.10	sim	> 0,5	0.54	sim
77	LA	>12	10.0	não	12 a 30	8.0	não	< 0,5	0.10	sim	0 a 3	1.00	sim
78	LG	12 a 30	12.2	sim	12 a 30	10.4	não	< 0,5	0.00	sim	> 0,5	0.55	sim
79	LA	>12	14.5	sim	12 a 30	10.1	não	< 0,5	0.00	sim	0 a 3	0.54	sim
80	LA	>12	7.1	não	12 a 30	2.6	não	< 0,5	0.00	sim	0 a 3	0.40	sim
81	NA	12 a 30	7.0	não	4 a 30	4.3	sim	< 0,5	0.00	sim	0 a 3	0.11	sim

Verificação da concordância entre resultados previstos pela Classificação MCT e obtidos em laboratório, para as amostras estudadas.

Amostra	Propriedades Classe MCT	Mini-CBR - Hm (%)			Mini-CBR - 24 h (%)			Expansão (%)			Contração (%)		
		Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância	Previsão	Resultado	Concordância
82	NA [*]	12 a 30	6.0	não	4 a 30	4.0	não	< 0,5	0.02	sim	0 a 3	0.30	sim
83	NS [*]	4 a 30	7.6	sim	0 a 12	2.2	sim	> 3	1.16	não	0,5 a 3	1.81	sim
84	NS [*]	4 a 30	6.0	sim	0 a 12	2.2	sim	> 3	0.08	não	0,5 a 3	0.58	sim
85	NA [*]	12 a 30	8.5	não	4 a 30	2.0	não	< 0,5	0.15	sim	0 a 3	0.20	sim
86	NS [*]	4 a 30	5.0	sim	0 a 12	2.2	sim	> 3	0.20	não	0,5 a 3	0.30	não
87	NS [*]	4 a 30	16.0	sim	0 a 12	3.2	sim	> 3	0.00	não	0,5 a 3	0.23	não
88	NA [*]	12 a 30	6.8	não	4 a 30	5.0	sim	< 0,5	0.02	sim	0 a 3	0.18	sim
89	NS [*]	4 a 30	8.0	sim	0 a 12	2.0	sim	> 3	0.14	não	0,5 a 3	0.15	não
90	LG [*]	12 a 30	4.0	não	12 a 30	2.8	não	< 0,5	0.00	sim	> 0,5	1.45	sim
91	LG [*]	12 a 30	11.0	não	12 a 30	7.1	não	< 0,5	0.44	sim	> 0,5	0.92	sim
92	LG [*]	12 a 30	14.8	sim	12 a 30	8.0	não	< 0,5	0.25	sim	> 0,5	1.00	sim
93	LG [*]	12 a 30	8.0	não	12 a 30	5.9	não	< 0,5	0.39	sim	> 0,5	0.85	sim
94	LG [*]	12 a 30	11.8	não	12 a 30	6.0	não	< 0,5	0.64	não	> 0,5	2.11	sim
95	NA [*]	12 a 30	6.0	não	4 a 30	4.5	sim	< 0,5	0.00	sim	0 a 3	0.64	sim
96	LG [*]	12 a 30	5.9	não	12 a 30	3.5	não	< 0,5	0.09	sim	> 0,5	0.33	sim
97	NA [*]	12 a 30	10.0	não	4 a 30	6.9	sim	< 0,5	0.00	sim	0 a 3	0.36	sim
98	NS [*]	4 a 30	3.5	não	0 a 12	2.3	sim	> 3	0.00	não	0,5 a 3	0.05	não
99	LG [*]	12 a 30	4.3	não	12 a 30	2.1	não	< 0,5	0.00	sim	> 0,5	0.48	não
100	LA [*]	>12	12.0	sim	12 a 30	8.0	não	< 0,5	0.00	sim	0 a 3	0.42	sim
101	LA [*]	>12	12.2	sim	12 a 30	10.1	não	< 0,5	0.12	sim	0 a 3	0.30	sim

ANEXO J

REGRESSÕES LINEARES SIMPLES

REGRESSÕES LINEARES SIMPLES

Neste item, apresentam-se as equações de regressão e os coeficientes de determinação (R^2) que correlacionaram as propriedades geotecnicas do solo e o valor de azul que apresentaram o coeficiente de determinação (R^2) menor que 0,5.

As propriedades estimadas são: massa específica seca máxima, mini-CBR na umidade de moldagem, mini-CBR após 24 h de imersão e expansão na energia normal e intermediária. Todos os valores foram obtidos nas umidades ótimas.

J.1. MASSA ESPECÍFICA SECA MÁXIMA

A relação entre a massa específica seca máxima e o valor de azul para os solos estudados, nas energias de compactação normal e intermediária, é mostrada nas figuras J.1 e J.2, assim como as equações que descrevem essas relações, com os respectivos coeficientes de determinação (R^2) para cada modelo.




Figura J.1 – Relação entre a massa específica seca máxima na energia normal e o valor de azul.




Figura J.2 – Relação entre a massa específica seca máxima na energia intermediária e o valor de azul.

J.2. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA

A relação entre o mini-CBR na umidade de moldagem obtido na umidade ótima e o valor de azul para os solos estudados, nas energias de compactação normal e intermediária, é mostrada nas figuras J.3 e J.4, assim como as equações que descrevem essas relações, com os respectivos coeficientes de determinação (R^2) para cada modelo.




Figura J.3 – Relação entre o mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal e o valor de azul.




Figura J.4 – Relação entre o mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária e o valor de azul.

J.3. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA

A relação entre o mini-CBR após 24 h de imersão obtido na umidade ótima e o valor de azul para os solos estudados, nas energias de compactação normal e intermediária, é mostrada nas figuras J.5 e J.6, assim como as equações que descrevem essas relações, com os respectivos coeficientes de determinação (R^2) para cada modelo.




Figura J.5 – Relação entre o mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal e o valor de azul.




Figura J.6 – Relação entre o mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária e o valor de azul.

J.4. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA

A relação entre a expansão obtida na umidade ótima e o valor de azul para os solos estudados, nas energias de compactação normal e intermediária, é mostrada nas figuras J.7 e J.8, assim como as equações que descrevem essas relações, com os respectivos coeficientes de determinação (R^2) para cada modelo.




Figura J.7 – Relação entre a expansão obtida na umidade ótima na energia normal e o valor de azul.




Figura J.8 – Relação entre a expansão obtida na umidade ótima na energia intermediária e o valor de azul.

ANEXO L

REDES NEURAIS ARTIFICIAIS

REDES NEURAIIS ARTIFICIAIS

Neste item, apresentam-se os outros cento e oitenta e cinco modelos de Redes Neurais Artificiais (RNAs) que foram utilizados para estimar as propriedades dos solos. As propriedades estimadas (número de modelos para cada uma) são:

1. umidade ótima na energia normal (24) e na intermediária (16);
2. massa específica seca máxima na energia normal (16) e na intermediária (16);
3. energia mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal (18) e na intermediária (17);
4. mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal (17) e na intermediária (17);
5. expansão obtida na umidade ótima na energia normal (11) e na intermediária (11);
6. contração obtida na umidade ótima na energia normal (11) e na intermediária (11).

As Tabelas I.1 a I.15 descreve-se, para cada modelo implementado para a previsão de uma propriedade, a arquitetura, as propriedades empregadas na camada de entrada, o coeficiente de determinação (R^2) das retas de regressão dos gráficos com os valores reais das propriedades do solo (ensaios laboratoriais) *versus* os previstos pelas RNAs e o erro médio relativo (EMR) entre esses mesmos valores.

Tabela I.1. - Modelos de RNAs para previsão da umidade ótima na energia normal (W_{on}).

RNA	Entradas	Saída	Arquitetura	R^2	EMR
1	W_{oi} (%)	W_{on} (%)	2-3-1	0,95	8,67
2	ρ_i (g/cm ³)		2-5-2-1	0,95	9,11
3	W_{oi} (%)		3-6-1	0,95	9,09
4	ρ_i (g/cm ³) V_a		3-6-2-1	0,94	10,87
5	W_{oi} (%)		3-6-1	0,95	8,22
6	ρ_i (g/cm ³)		3-6-2-1	0,94	9,61
7	C_a		3-14-4-1	0,95	9,52
8	W_{oi} (%)		6-6-1	0,95	12,4
9	ρ_i (g/cm ³)		6-6-2-1	0,93	16,6
10	V_a #(0,42;0,074;0,005)		6-14-4-1	0,93	13,09

Tabela I.2. - Modelos de RNAs para previsão da umidade ótima na energia normal (Won).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
11	Woi (%)	Won (%)	6-6-1	0,95	11,57
12	ρ_i (g/cm ³)		6-6-2-1	0,93	16,26
13	Ca #(0,42;0,074;0,005)		6-14-4-1	0,93	12,33
14	Va #(0,42;0,074;0,005)		4-5-3-1	0,72	21,35
15	Ca #(0,42;0,074;0,005)		4-5-1	0,78	15,72
16	#(0,42;0,074;0,005)		3-5-1	0,57	19,26
17	Croma Valor Va		3-12-6-1	0,34	32,14
18	Croma Va		2-13-6-1 2-5-2-2-1	-	-
19	Croma Valor		2-11-6-1 2-7-2-2-1	-	-
20	c', d', Pi, e'		4-11-1	0,32	32,18
21	c', d', Pi, e' #(0,42;0,074;0,005)		7-12-1	0,76	16,06
22	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-16-1	0,75	14,75
23	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-16-1	0,81	13,70
24	c', d', Pi, e' Va		5-12-1	0,62	16,72

Tabela I.3. - Modelos de RNAs para previsão da umidade ótima na energia intermediária (Woi).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Won (%) ρ_n (g/cm ³)	Woi (%)	2-5-1	0,96	10,77
2	Won (%) ρ_n (g/cm ³) Va		3-6-1	0,96	10,07
3	Won (%) ρ_n (g/cm ³) Ca		3-6-1	0,96	10,58

Tabela I.4. - Modelos de RNAs para previsão da umidade ótima na energia intermediária (Woi).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
4	Won (%) ρ_n (g/cm ³) Va #(0,42;0,074;0,005)	Woi (%)	6-6-1	0,95	10,03
5	Won (%) ρ_n (g/cm ³) Ca #(0,42;0,074;0,005)		6-6-1	0,95	9,88
6	Va #(0,42;0,074;0,005)		4-5-1	0,86	16,91
7	Ca #(0,42;0,074;0,005)		4-5-3-3-1	0,57	36,22
8	#(0,42;0,074;0,005)		3-4-2-2-1	0,87	14,42
9	Croma Valor Va		3-12-6-1	-	-
10	Croma Va		2-13-6-1 2-5-2-2-1	-	-
11	Croma Valor		2-11-6-1 2-7-2-2-1	-	-
12	c', d', Pi, e'		4-14-1	0,37	27,57
13	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-1	0,74	18,20
14	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-15-1	0,79	16,23
15	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-15-1	0,82	16,21
16	c', d', Pi, e' Va		5-12-1	0,40	21,32

Tabela I.5. - Modelos de RNAs para previsão da massa específica seca máxima na energia normal (ρ_n).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Woi (%) ρ_i (g/cm ³)	ρ_n (%)	2-4-1	0,86	3,29
2	Woi (%) ρ_i (g/cm ³) Va		3-4-1	0,83	2,91
3	Woi (%) ρ_i (g/cm ³) Va #(0,42;0,074;0,005)		6-6-1	0,81	3,83
4	Woi (%) ρ_i (g/cm ³) #(0,42;0,074;0,005)		5-7-1	0,83	4,02
5	Va #(0,42;0,074;0,005)		4-5-3-1	0,34	5,24
6	#(0,42;0,074;0,005)		3-6-2-2-1	0,58	5,21
7	Woi (%) ρ_i (g/cm ³) mini-CBRhmi		3-4-1	0,76	3,43
8	Woi (%) ρ_i (g/cm ³) mini-CBRhmi mini-CBR24hi		4-9-1	0,74	3,87
9	Croma Valor Va		3-12-6-1	0,13	6,69
10	Croma Va		2-11-6-1 2-7-2-2-1	-	-
11	Croma Valor		2-11-6-1 2-7-2-2-1	-	-
12	c', d', Pi, e'		4-13-6-1	0,004	8,83
13	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-6-1	0,46	5,85
14	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-13-6-1-	0,21	6,83
15	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-13-6-1-	0,50	3,66
16	c', d', Pi, e' Va		5-13-6-1-	0,08	6,67

Tabela I.6. - Modelos de RNAs para previsão da massa específica seca máxima na energia intermediária (ρ_i).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Won (%) ρ_n (g/cm ³)	ρ_i (%)	2-4-1	0,52	5,12
2	Won (%) ρ_n (g/cm ³) Va		3-4-1	0,68	4,87
3	Won (%) ρ_n (g/cm ³) Va #(0,42;0,074;0,005)		6-8-1	0,70	6,14
4	Won (%) ρ_n (g/cm ³) #(0,42;0,074;0,005)		5-7-1	0,62	6,98
5	Va #(0,42;0,074;0,005)		4-5-3-3-1	0,08	8,09
6	#(0,42;0,074;0,005)		3-12-5-5-1	0,07	10,17
7	Won (%) ρ_n (g/cm ³) mini-CBRhmn		3-4-1	0,60 (linear) 0,76 (polinomial)	5,94
8	Woi (%) ρ_i (g/cm ³) mini-CBRhmn mini-CBR24hn		4-5-1	0,35 (linear) 0,61 (polinomial)	8,82
9	Croma Valor Va		3-13-5-1	-	-
10	Croma Va		2-14-6-1	-	-
11	Croma Valor		2-13-5-1	-	-
12	c', d', Pi, e'		2-13-6-1	0,03	9,62
13	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-6-1	0,02	11,67
14	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-13-6-1	0,11	12,10
15	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-13-6-1	0,25	8,54
16	c', d', Pi, e' Va		5-13-6-1	0,05	10,75

Tabela I.7. - Modelos de RNAs para previsão do mini-CBR na umidade ótima obtido na umidade de moldagem na energia normal (Mini-CBRhmn).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	mini-CBRhmi mini-CBR24hi	Mini-CBRhmn	2-14-5-5-1	0,20	33,10
2	mini-CBRhmi mini-CBR24hi Va		3-11-6-1	0,22	34,56
3	mini-CBRhmi mini-CBR24hi Va #(0,42;0,074;0,005)		6-8-1	0,36	40,44
			6-8-3-1	0,42	40,04
			6-11-6-6-1	0,42	44,88
4	Woi (%) ρ_i (g/cm ³)		2-13-7-1	0,02	83,27
5	mini-CBR24hi Va #(0,42;0,074;0,005)		5-11-5-1	0,33	31,99
6	mini-CBRhmi Va #(0,42;0,074;0,005)		5-7-1	0,27	40,01
7	mini-CBRhmi Va		2-13-7-1	0,45	31,45
8	mini-CBRhmi #(0,42;0,074;0,005)		4-11-5-1	0,33	30,10
9	Va #(0,42;0,074;0,005)		4-12-8-1	0,0024	55,39
10	#(0,42;0,074;0,005)		3-13-7-1	0,011	61,63
11	Won (%) ρ_n (g/cm ³)		2-11-7-1	0,05	73,48
12	Won (%) ρ_n (g/cm ³) #(0,42;0,074;0,005)		5-11-6-1	0,001	84,59
13	Won (%) ρ_n (g/cm ³) Va #(0,42;0,074;0,005)		6-13-7-1	0,05	73,35
14	c', d', Pi, e'		4-13-7-1	0,0007	45,81
15	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-7-1	0,21	54,25
16	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-13-7-1	0,08	63,60
17	c', d', Pi, e' Ca #(0,42;0,074;0,005)	8-13-7-1	0,12	39,87	
18	c', d', Pi, e' Va	5-13-7-1	0,08	83,58	

Tabela I.8. - Modelos de RNAs para previsão do mini-CBR na umidade ótima obtido na umidade de moldagem na energia intermediária (Mini-CBRhmi).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Woi (%) ρ_i (g/cm ³)	mini-CBRhmi	2-13-6-1	0,02	146,77
2	Woi (%) ρ_i (g/cm ³) #(0,42;0,074;0,005)		5-11-6-1	0,16	118,53
3	Woi (%) ρ_i (g/cm ³) Va #(0,42;0,074;0,005)		6-14-7-1	0,07	129,41
4	c', d', Pi, e'		4-14-6-1	0,02	113,53
5	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-6-1	0,02	143,37
6	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-14-7-1	0,05	119,47
7	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-14-6-1	0,08	163,82
8	c', d', Pi, e' Va		8-14-7-1	0,11	131,74
9	mini-CBRhmn mini-CBR24hn		2-19-7-6-1	0,25	40,41
10	mini-CBRhmn mini-CBR24hn Va		3-11-6-1	0,23	40,63
11	mini-CBRhmn mini-CBR24hn Va #(0,42;0,074;0,005)		6-14-6-1	0,16	55,69
12	Won (%) ρ_n (g/cm ³)		2-13-6-1	0,0003	107,10
13	mini-CBRhmn Va #(0,42;0,074;0,005)		5-13-6-1	0,20	118,71
14	mini-CBRhmn Va		5-14-5-1	-	-
15	mini-CBRhmn #(0,42;0,074;0,005)		2-13-6-1	0,08	65,37
16	Va #(0,42;0,074;0,005)		4-13-6-1	0,02	157,04
17	#(0,42;0,074;0,005)		3-13-6-1	0,004	170,14

Tabela I.9. - Modelos de RNAs para previsão do mini-CBR na umidade ótima obtido após 24 h de imersão na energia normal (Mini-CBR24hn).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	mini-CBRhmi mini-CBR24hi	mini- CBR24hn	2-14-5-1	0,25	58,75
2	mini-CBRhmi mini-CBR24hi Va		3-11-6-1	0,27	53,00
3	mini-CBRhmi mini-CBR24hi Va #(0,42;0,074;0,005)		6-11-1	0,21	69,28
4	Woi (%) ρ_i (g/cm ³)		2-11-7-1	-	-
5	mini-CBR24hi Va #(0,42;0,074;0,005)		5-11-1	0,22	49,08
6	mini-CBR24hi Va		2-11-7-1-	-	-
7	mini-CBR24hi #(0,42;0,074;0,005)		4-11-5-1	0,34	38,94
8	Va #(0,42;0,074;0,005)		4-11-6-1	0,03	90,91
9	#(0,42;0,074;0,005)		3-11-6-1	0,03	64,96
10	Won (%) ρ_n (g/cm ³)		2-11-7-1	0,15	87,68
11	Won (%) ρ_n (g/cm ³) #(0,42;0,074;0,005)		5-11-7-1	0,14	53,79
12	Won (%) ρ_n (g/cm ³) Va #(0,42;0,074;0,005)		6-13-7-1	0,23	60,75
13	c', d', Pi, e'		4-12-6-1	0,002	104,74
14	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-7-1	0,02	58,47
15	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-16-8-1	0,07	62,38
16	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-13-7-1	0,02	61,81
17	c', d', Pi, e' Va		5-13-7-1	0,07	80,03

Tabela I.10. - Modelos de RNAs para previsão do mini-CBR na umidade ótima obtido após 24 h de imersão na energia intermediária (Mini-CBR24hi).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Woi (%) ρ_i (g/cm ³)	mini-CBR24hi	2-11-6-1	0,02	167,71
2	Woi (%) ρ_i (g/cm ³) #(0,42;0,074;0,005)		5-11-7-1	0,04	167,32
3	Woi (%) ρ_i (g/cm ³) Va #(0,42;0,074;0,005)		6-14-7-1	0,04	116,43
4	c', d', Pi, e'		4-12-8-1	0,02	130,56
5	c', d', Pi, e' #(0,42;0,074;0,005)		7-13-6-1	0,013	129,89
6	c', d', Pi, e' Va #(0,42;0,074;0,005)		8-13-6-1	0,13	60,74
7	c', d', Pi, e' Ca #(0,42;0,074;0,005)		8-16-6-1	0,20	121,83
8	c', d', Pi, e' Va		5-13-6-1	0,02	116,88
9	mini-CBRhmn mini-CBR24hn		2-13-5-1	0,16	69,72
10	mini-CBRhmn mini-CBR24hn Va		3-11-6-1	0,08	105,82
11	mini-CBRhmn mini-CBR24hn Va #(0,42;0,074;0,005)		6-13-6-1	0,20	48,81
12	Won (%) ρ_n (g/cm ³)		2-15-8-1	0,13	82,17
13	mini-CBR24hn Va #(0,42;0,074;0,005)		5-13-6-1	0,15	84,91
14	mini-CBR24hn Va		5-11-6-1	0,04	94,83
15	mini-CBR24hn #(0,42;0,074;0,005)		2-13-6-1	0,53	108,27
16	Va #(0,42;0,074;0,005)		4-13-7-1	0,008	152,04
17	#(0,42;0,074;0,005)		3-11-7-1	0,04	96,42

Tabela I.11. - Modelos de RNAs para previsão da expansão obtida na umidade ótima na energia normal (Expansão).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Expansãoi (%) Va	Expansão (%)	2-15-5-1	0,32	-
2	Expansãoi (%) Va #(0,42;0,074;0,005)		5-12-6-1	0,52	-
3	Va #(0,42;0,074;0,005)		4-13-6-1	0,53	-
4	Expansãoi (%) #(0,42;0,074;0,005)		4-11-6-1	0,36	-
5	#(0,42;0,074;0,005)		3-11-5-1	0,21	-
6	Won (%) Va		2-14-1	0,05	-
7	Won (%) Ca		2-14-6-1	0,02	-
8	Won (%) #(0,42;0,074;0,005) Va		2-12-1	0,34	-
9	Won (%) #(0,42;0,074;0,005) Ca		5-12-1	0,01	-
10	Won (%) #(0,42;0,074;0,005)		4-11-1	0,15	-
11	#(0,42;0,074;0,005)		3-11-1	0,05	-

Tabela I.12. - Modelos de RNAs para previsão da expansão obtida na umidade ótima na energia intermediária (Expansãoi).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Expansãoi (%) Va	Expansãoi (%)	2-13-6-1	0,25	-
2	Expansãoi (%) Va #(0,42;0,074;0,005)		5-12-6-1	0,20	-
3	Va #(0,42;0,074;0,005)		4-12-6-1	0,018	-
4	Expansãoi (%) #(0,42;0,074;0,005)		4-11-6-1	0,41	-
5	#(0,42;0,074;0,005)		3-11-5-1	0,01	-
6	Woi (%) Va		2-14-6-1	0,13	-
7	Woi (%) Ca		2-14-6-1	-	-
8	Woi (%) #(0,42;0,074;0,005) Va		5-12-6-1	0,05	-
9	Woi (%) #(0,42;0,074;0,005) Ca		5-12-6-1	-	-
10	Woi (%) #(0,42;0,074;0,005)		4-13-6-1	0,15	-
11	#(0,42;0,074;0,005)		3-13-6-1	0,15	-

Tabela I.13. - Modelos de RNAs para previsão da contração obtida na umidade ótima na energia normal (Contração).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Contraçãoi (%) Va	Contração (%)	2-14-5-1	0,63	43,8
2	Contraçãoi (%) Va #(0,42;0,074;0,005)		5-12-6-1	0,70	45,4
3	Va #(0,42;0,074;0,005)		4-12-6-1	0,44	74,25
4	Contraçãoi (%) #(0,42;0,074;0,005)		4-15-6-1	0,51	51,02
5	#(0,42;0,074;0,005)		3-11-5-1	0,46	64,02
6	Won (%) Va		2-11-5-1	0,40	61,60
7	Won (%) Ca		2-11-1	0,57	69,70

Tabela I.14. - Modelos de RNAs para previsão da contração obtida na umidade ótima na energia normal (Contração).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
8	Won (%) #(0,42;0,074;0,005) Va	Contração (%)	2-11-1	0,25	65,36
9	Won (%) #(0,42;0,074;0,005) Ca		5-12-1	0,36	57,09
10	Won (%) #(0,42;0,074;0,005)		4-11-1	0,38	69,36
11	#(0,42;0,074;0,005)		3-11-1	0,42	51,98

Tabela I.15. - Modelos de RNAs para previsão da contração obtida na umidade ótima na energia intermediária (Contraçãoi).

RNA	Entradas	Saída	Arquitetura	R ²	EMR
1	Contração (%) Va	Contraçãoi (%)	2-14-5-1	0,64	80,30
2	Contração (%) Va #(0,42;0,074;0,005)		5-12-6-1	0,68	96,73
3	Va #(0,42;0,074;0,005)		4-10-6-1	0,39	145,33
4	Contração (%) #(0,42;0,074;0,005)		4-11-5-1	0,85	54,60
5	#(0,42;0,074;0,005)		3-12-6-1	0,37	151,32
6	Woi (%) Va		2-14-1	0,66	88,06
7	Woi (%) Ca		2-11-5-1	0,75	76,84
8	Woi (%) #(0,42;0,074;0,005) Va		5-11-1	0,33	122,17
9	Woi (%) #(0,42;0,074;0,005) Ca		5-12-1	0,50	134,22
10	Woi (%) #(0,42;0,074;0,005)		4-11-1	0,50	131,69
11	#(0,42;0,074;0,005)		3-11-1	0,27	191,01

ANEXO M

REGRESSÕES MÚLTIPLAS

REGRESSÕES MÚLTIPLAS

Neste item, apresentam-se as cento e sessenta e nove equações de regressão e os coeficientes de determinação (R^2) que correlacionam as propriedades entre si e que não foram modelos similares aos das Redes Neurais Artificiais (RNAs) que apresentaram o máximo coeficiente de determinação ($R^2_{\text{máx}}$) e o mínimo erro médio relativo ($\text{EMR}_{\text{mín}}$) para cada propriedade estimada.

As propriedades estimadas (número de modelos de regressão múltipla para cada uma) são:

1. umidade ótima na energia normal (20) e na intermediária (17);
2. massa específica seca máxima na energia normal (13) e na intermediária (14);
3. energia mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal (15) e na intermediária (17);
4. mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal (16) e na intermediária (15);
5. expansão obtida na umidade ótima na energia normal (10) e na intermediária (10);
6. contração obtida na umidade ótima na energia normal (10) e na intermediária (12).

A.1. UMIDADE ÓTIMA NA ENERGIA NORMAL

As expressões A.1 a A.20 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a umidade ótima na energia normal em função de outras propriedades.

$$W_{on} = 1,02W_{oi} + 0,11p_i + 1,67 \quad (\text{A.1})$$

$$R^2 = 0,97$$

$$W_{on} = 0,99W_{oi} + 0,46p_i + 0,14CA - 0,04(\#0,42) + 0,04(\#0,074) - 0,009(\#0,005) + 2,39 \quad (\text{A.2})$$

$$R^2 = 0,97$$

$$\begin{aligned} \text{Won} &= 0,03\text{CA} - 0,16(\#0,42) + 0,19(\#0,074) + 0,12(\#0,005) + 19,80 & (\text{A.3}) \\ R^2 &= 0,78 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 1,25\text{Va} + 0,13(\#0,42) + 0,12(\#0,074) + 0,12(\#0,005) + 17,16 & (\text{A.4}) \\ R^2 &= 0,81 \end{aligned}$$

$$\begin{aligned} \text{Won} &= -0,16(\#0,42) + 0,18(\#0,074) + 0,11(\#0,005) + 19,99 & (\text{A.5}) \\ R^2 &= 0,78 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 0,17(\#0,074) + 0,12(\#0,005) + 4,76 & (\text{A.6}) \\ R^2 &= 0,78 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 1,29\text{Va} + 0,10(\#0,074) + 0,13(\#0,005) + 5,22 & (\text{A.7}) \\ R^2 &= 0,82 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 3,64\text{Va} + 0,03(\#0,42) + 5,99 & (\text{A.8}) \\ R^2 &= 0,61 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 1,25\text{Va} - 0,13(\#0,42) + 0,12(\#0,074) + 0,12(\#0,005) + 17,16 & (\text{A.9}) \\ R^2 &= 0,81 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 0,03\text{CA} - 0,16(\#0,42) + 0,18(\#0,074) + 0,11(\#0,005) + 19,80 & (\text{A.10}) \\ R^2 &= 0,78 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 0,99\text{Woi} + 0,30\text{pi} + 0,15\text{Va} + 1,36 & (\text{A.11}) \\ R^2 &= 0,97 \end{aligned}$$

$$\begin{aligned} \text{Won} &= 0,97\text{Woi} + 0,33\text{pi} + 0,09\text{Va} - 0,03(\#0,42) + 0,02(\#0,074) - 0,01(\#0,005) + & \\ & 3,84 & (\text{A.12}) \\ R^2 &= 0,97 \end{aligned}$$

$$\text{Won} = 8,12c' - 0,03\text{Pi} - 0,01d' + 7,80e' - 0,39 \quad (\text{A.13})$$

$$R^2 = 0,62$$

$$\text{Won} = 2,65c' - 0,01\text{Pi} - 0,0005d' + 4,38e' - 0,12(\#0,42) + 0,18(\#0,074) + 0,04(\#0,005) + 11,74 \quad (\text{A.14})$$

$$R^2 = 0,81$$

$$\text{Won} = 2,61c' - 0,01\text{Pi} - 0,001d' + 3,19e' + 1,16\text{Va} - 0,09(\#0,42) + 0,12(\#0,074) + 0,04(\#0,005) + 10,53 \quad (\text{A.15})$$

$$R^2 = 0,84$$

$$\text{Won} = 0,13c' + 2,73\text{Pi} - 0,01d' - 0,0005e' + 4,13\text{CA} - 0,1(\#0,42) + 0,15(\#0,074) + 0,08(\#0,005) + 9,42 \quad (\text{A.16})$$

$$R^2 = 0,82$$

$$\text{Won} = 5,13c' - 0,02\text{Pi} - 0,005d' + 3,74e' + 2,29\text{Va} + 2,26 \quad (\text{A.17})$$

$$R^2 = 0,78$$

$$\text{Won} = 0,12\text{croma} + 3,54\text{Va} + 6,47 \quad (\text{A.18})$$

$$R^2 = 0,62$$

$$\text{Won} = -0,25\text{valor} + 0,15\text{croma} + 3,42\text{Va} + 7,73 \quad (\text{A.19})$$

$$R^2 = 0,62$$

$$\text{Won} = -2,32\text{valor} + 0,48\text{croma} + 22,04 \quad (\text{A.20})$$

$$R^2 = 0,19$$

onde:

Won: umidade ótima na energia normal, em %;

Woi: umidade ótima na energia intermediária, em %;

pi: massa específica seca máxima na energia intermediária, em g/cm^3 ;

Va: valor de azul, em 10^{-3} g/g ;

CA: coeficiente de atividade, em 10^{-3} g/g%;

(#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 0,42 mm, 0,074mm e 0,005 mm (%);

c': índice da Classificação MCT;

Pi: perda de massa por imersão, em %;

d': inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e': índice da Classificação MCT;

croma: traduz a saturação ou a intensidade do colorido de um solo;

valor: traduz a tonalidade mais clara ou mais escura da cor de um solo.

A.2. UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

As expressões A.21 a A.37 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) e para determinar a umidade ótima na energia intermediária em função de outras propriedades.

$$W_{oi} = 0,94W_{on} - 0,72\rho_n + 0,04 \quad (\text{A.21})$$

$$R^2 = 0,97$$

$$W_{oi} = 0,92W_{on} - 0,53\rho_n + 0,15V_a - 0,22 \quad (\text{A.22})$$

$$R^2 = 0,97$$

$$W_{oi} = 0,85W_{on} - 0,78\rho_n + 0,12V_a + 0,01(\#0,42) - 0,003(\#0,074) + 0,03(\#0,005) - 0,30 \quad (\text{A.23})$$

$$R^2 = 0,97$$

$$W_{oi} = 0,14CA - 0,11(\#0,42) + 0,13(\#0,074) + 0,18(\#0,005) + 12,60 \quad (\text{A.24})$$

$$R^2 = 0,80$$

$$W_{oi} = 0,15(\#0,074) + 0,14(\#0,005) - 2,97 \quad (\text{A.25})$$

$$R^2 = 0,79$$

$$Woi = 1,21Va - 0,10(\#0,42) + 0,1(\#0,074) + 0,14(\#0,005) + 12,63 \quad (A.26)$$

$$R^2 = 0,82$$

$$Woi = 1,21Va - 0,10(\#0,42) + 0,10(\#0,074) + 0,14(\#0,005) + 12,63 \quad (A.27)$$

$$R^2 = 0,82$$

$$Woi = -0,13(\#0,42) + 0,16(\#0,074) + 0,13(\#0,005) + 15,37 \quad (A.28)$$

$$R^2 = 0,79$$

$$Woi = 7,90c' - 0,03Pi - 0,008d' + 6,86e' - 1,32 \quad (A.29)$$

$$R^2 = 0,67$$

$$Woi = 2,95c' - 0,02Pi + 0,001d' + 3,90e' - 0,07(\#0,42) + 0,16(\#0,074) + 0,03(\#0,005) + 5,89 \quad (A.30)$$

$$R^2 = 0,83$$

$$Woi = 3,04c' - 0,016Pi + 0,001d' + 3,61e' + 0,15CA - 0,05(\#0,42) + 0,13(\#0,074) + 0,07(\#0,005) + 3,20 \quad (A.31)$$

$$R^2 = 0,84$$

$$Woi = 2,91c' - 0,01Pi + 0,001d' + 2,74e' + 1,13Va - 0,05(\#0,42) + 0,10(\#0,074) + 0,03(\#0,005) + 4,72 \quad (A.32)$$

$$R^2 = 0,86$$

$$Woi = 0,15c' + 3,04Pi - 0,02d' + 0,001e' + 3,61CA - 0,05(\#0,42) + 0,13(\#0,074) + 0,07(\#0,005) + 3,20 \quad (A.33)$$

$$R^2 = 0,84$$

$$Woi = 5,13c' - 0,02Pi - 0,003d' + 3,09e' + 2,13Va + 1,15 \quad (A.34)$$

$$R^2 = 0,81$$

$$Woi = 0,15croma + 3,64Va + 8,31 \quad (A.35)$$

$$R^2 = 0,62$$

$$Woi = -0,26valor + 0,14croma + 3,51Va + 7,82 \quad (A.36)$$

$$R^2 = 0,62$$

$$Woi = -2,40valor + 0,5croma + 21,96 \quad (A.37)$$

$$R^2 = 0,20$$

onde:

Woi: umidade ótima na energia intermediária, em %;

Won: umidade ótima na energia normal, em %;

pn: massa específica seca máxima na energia normal, em g/cm^3 ;

Va: valor de azul, em $10^{-3} g/g$;

CA: coeficiente de atividade, em $10^{-3} g/g\%$;

~~(#2,00), (#0,42), (#0,074), (#0,005)~~: frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm (%);

c': índice da Classificação MCT;

Pi: perda de massa por imersão, em %;

d': inclinação do ramo seco da curva de compactação, em $kg/m^3\%$;

e': índice da Classificação MCT;

croma: traduz a saturação ou a intensidade do colorido de um solo;

valor: traduz a tonalidade mais clara ou mais escura da cor de um solo.

A.3. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA NORMAL

As expressões A.38 a A.50 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a massa específica seca máxima na energia normal em função de outras propriedades.

$$pn = -0,006Woi + 0,56pi + 0,003Va \quad (A.38)$$

$$R^2 = 0,74$$

$$\rho_n = -0,006W_{oi} + 0,56\rho_i + 0,0033V_a + 0,0025(\#0,42) - 0,0012(\#0,074) + 0,0008(\#0,005) + 0,58 \quad (\text{A.39})$$

$$R^2 = 0,75$$

$$\rho_n = -0,007W_{oi} + 0,54\rho_i + 0,00004\text{mini-CBR}(\text{Hmi}) + 0,0008\text{mini-CBR}(24\text{hi}) + 0,84 \quad (\text{A.40})$$

$$R^2 = 0,74$$

$$\rho_n = -0,005W_{oi} + 0,56\rho_i + 0,0024(\#0,42) - 0,001(\#0,074) - 0,001(\#0,005) + 0,59 \quad (\text{A.41})$$

$$R^2 = 0,75$$

$$\rho_n = -0,07c' - 0,0004 P_i + 0,0006d' - 0,06e' + 0,001(\#0,42) - 0,004(\#0,074) + 0,0004(\#0,005) + 2,02 \quad (\text{A.42})$$

$$R^2 = 0,51$$

$$\rho_n = -0,07c' - 0,0004 P_i + 0,0007d' - 0,03e' - 0,03V_a + 0,0003(\#0,42) - 0,003(\#0,074) + 0,0002(\#0,005) + 2,05 \quad (\text{A.43})$$

$$R^2 = 0,54$$

$$\rho_n = -0,004c' - 0,08 P_i + 0,0004d' + 0,0006e' - 0,05CA + 0,0005(\#0,42) - 0,003(\#0,074) - 0,001(\#0,005) + 2,09 \quad (\text{A.44})$$

$$R^2 = 0,52$$

$$\rho_n = -0,12c' - 0,0004P_i + 0,001d' - 0,03e' - 0,05V_a + 2,06 \quad (\text{A.45})$$

$$R^2 = 0,50$$

$$\rho_n = -0,03V_a - 0,005(\#0,42) - 0,003(\#0,074) + 0,001(\#0,005) - 6,60 \quad (\text{A.46})$$

$$R^2 = 0,41$$

$$\rho_n = -0,002(\#0,42) - 0,005(\#0,074) + 0,002(\#0,005) + 2,16 \quad (\text{A.47})$$

$$R^2 = 0,38$$

$$p_n = 0,002V_a - 0,03(\#0,42) - 0,002(\#0,074) - 0,004(\#0,005) + 2,23 \quad (\text{A.48})$$

$$R^2 = 0,41$$

$$p_n = -0,18c' - 7,8 \cdot 10^{-5} P_i + 0,001d' - 0,12e' + 2,12 \quad (\text{A.49})$$

$$R^2 = 0,35$$

$$p_n = -0,04c_{\text{roma}} + 0,002V_a + 1,73 \quad (\text{A.50})$$

$$R^2 = 0,37$$

$$p_n = -0,01v_{\text{valor}} + 0,01c_{\text{roma}} - 0,07V_a + 2,03 \quad (\text{A.51})$$

$$R^2 = 0,37$$

$$p_n = -0,01v_{\text{valor}} - 0,07c_{\text{roma}} + 1,99 \quad (\text{A.50})$$

$$R^2 = 0,036$$

onde:

p_n : massa específica seca máxima na energia normal, em g/cm^3 ;

W_{oi} : umidade ótima na energia intermediária, em %;

p_i : massa específica seca máxima na energia intermediária, em g/cm^3 ;

V_a : valor de azul, em 10^{-3} g/g ;

CA : coeficiente de atividade em 10^{-3} g/g\% ;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm;

c' : traduz a argilosidade do solo;

P_i : perda de massa por imersão, em %;

d' : inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e' : expressa o caráter laterítico do solo;

mini-CBR(Hmi): mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, em %;

mini-CBR(24hi): mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, em %;

croma: traduz a saturação ou a intensidade do colorido de um solo;

valor: traduz a tonalidade mais clara ou mais escura da cor de um solo.

A.4. MASSA ESPECÍFICA SECA MÁXIMA NA ENERGIA INTERMEDIÁRIA

As expressões A.51 a A.64 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a massa específica seca máxima na energia intermediária em função de outras propriedades.

$$\rho_i = -0,0003W_{on} + 0,97\rho_n - 0,001\text{mini-CBR(Hmn)} + 0,004\text{mini-CBR(24hn)} + 0,15 \quad (\text{A.51})$$

$$R^2 = 0,69$$

$$\rho_i = 0,0006W_{on} + 1,02\rho_n + 0,06 \quad (\text{A.52})$$

$$R^2 = 0,68$$

$$\rho_i = -0,0008W_{on} + 0,97\rho_n - 0,007(\#0,42) - 0,0008(\#0,074) + 0,0015(\#0,005) + 0,87 \quad (\text{A.53})$$

$$R^2 = 0,70$$

$$\rho_i = -0,0003W_{on} + 0,99\rho_n + 0,0012\text{mini-CBR(Hmn)} + 0,097 \quad (\text{A.54})$$

$$R^2 = 0,69$$

$$\rho_i = +0,003V_a + 0,12(\#0,42) - 0,01(\#0,074) - 0,003(\#0,005) - 8,95 \quad (\text{A.55})$$

$$R^2 = 0,36$$

$$\rho_i = -0,01(\#0,42) - 0,006(\#0,074) + 0,003(\#0,005) - 3,59 \quad (\text{A.56})$$

$$R^2 = 0,30$$

$$\rho_i = -0,19c' - 0,0003 P_i + 0,001d' - 0,05e' + 2,17 \quad (\text{A.57})$$

$$R^2 = 0,25$$

$$\rho_i = -0,08c' - 0,0005 Pi + 0,001d' - 0,01e' - 0,006(\#0,42) - 0,005(\#0,074) + 0,002(\#0,005) + 2,76 \quad (\text{A.58})$$

$$R^2 = 0,39$$

$$\rho_i = -0,08c' - 0,001 Pi + 0,001d' + 0,04e' - 0,05Va - 0,01(\#0,42) - 0,002(\#0,074) + 0,001(\#0,005) + 2,81 \quad (\text{A.59})$$

$$R^2 = 0,45$$

$$\rho_i = -0,01c' - 0,08 Pi - 0,001d' + 0,001e' + 0,05CA - 0,01(\#0,42) - 0,003(\#0,074) - 0,001(\#0,005) + 2,88 \quad (\text{A.60})$$

$$R^2 = 0,42$$

$$\rho_i = -0,11c' - 0,001Pi + 0,001d' + 0,07e' - 0,07Va + 2,1 \quad (\text{A.61})$$

$$R^2 = 0,41$$

$$\rho_i = 0,02croma + 0,01Va + 1,66 \quad (\text{A.62})$$

$$R^2 = 0,29$$

$$\rho_i = 0,01valor - 0,06croma + 2,02 \quad (\text{A.63})$$

$$R^2 = 0,06$$

$$\rho_i = -0,02valor + 0,01croma - 0,07Va + 1,99 \quad (\text{A.64})$$

$$R^2 = 0,29$$

onde:

ρ_i : massa específica seca máxima na energia intermediária, em g/cm^3 ;

ρ_n : massa específica seca máxima na energia normal, em g/cm^3 ;

W_{on} : umidade ótima na energia normal, em %;

V_a : valor de azul, em 10^{-3} g/g ;

CA : coeficiente de atividade em $10^{-3} \text{ g/g}\%$;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm;

c' : traduz a argilosidade do solo;

P_i : perda de massa por imersão, em %;

d' : inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e' : expressa o caráter laterítico do solo;

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %.

croma: traduz a saturação ou a intensidade do colorido de um solo;

valor: traduz a tonalidade mais clara ou mais escura da cor de um solo.

A.5. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL

As expressões A.65 a A.79 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar o mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal em função de outras propriedades.

$$\text{mini-CBR(Hmn)} = 0,24\text{mini-CBR(Hmi)} + 0,11 \text{ mini-CBR(24hi)} + 4,5 \quad (\text{A.65})$$

$$R^2 = 0,52$$

$$\text{mini-CBR(Hmn)} = 0,24\text{mini-CBR(Hmi)} + 0,12\text{mini-CBR(24hi)} - 0,36V_a + 5,13 \quad (\text{A.66})$$

$$R^2 = 0,52$$

$$\begin{aligned} \text{mini-CBR(Hmn)} = & 0,25\text{mini-CBR(Hmi)} + 0,09\text{mini-CBR(24hi)} + 0,03V_a - \\ & 0,11(\#0,42) - 0,10(\#0,074) + 0,11(\#0,005) + 16,69 \quad (\text{A.67}) \end{aligned}$$

$$R^2 = 0,54$$

$$\text{mini-CBR(Hmn)} = 0,29\text{mini-CBR(Hmi)} + 0,03\text{Va} - 0,13(\#0,42) - 0,10(\#0,074) + 0,12(\#0,005) + 19,46 \quad (\text{A.68})$$

$$R^2 = 0,54$$

$$\text{mini-CBR(Hmn)} = -0,58(\#0,42) - 0,13(\#0,074) + 0,19(\#0,005) + 70,10 \quad (\text{A.69})$$

$$R^2 = 0,13$$

$$\text{mini-CBR(Hmn)} = -0,88\text{Va} - 0,60(\#0,42) - 0,09(\#0,074) + 0,19(\#0,005) + 78,09 \quad (\text{A.70})$$

$$R^2 = 0,15$$

$$\text{mini-CBR(Hmn)} = 0,19\text{Woi} + 16,21\text{pi} - 19,59 \quad (\text{A.71})$$

$$R^2 = 0,14$$

$$\text{mini-CBR(Hmn)} = 0,28\text{Won} + 24,65\text{pn} - 34,64 \quad (\text{A.72})$$

$$R^2 = 0,19$$

$$\text{mini-CBR(Hmn)} = -0,07\text{Won} + 21,21\text{pn} - 0,55(\#0,42) - 0,01(\#0,074) + 0,16(\#0,005) + 25,79 \quad (\text{A.73})$$

$$R^2 = 0,28$$

$$\text{mini-CBR(Hmn)} = -0,06\text{Won} + 21,07\text{pn} - 0,16\text{Va} - 0,55(\#0,42) - 0,003(\#0,074) + 0,16(\#0,005) + 26,16 \quad (\text{A.74})$$

$$R^2 = 0,28$$

$$\text{mini-CBR(Hmn)} = -3,83\text{c}' - 0,03\text{Pi} + 0,02\text{d}' + 1,30\text{e}' + 19,68 \quad (\text{A.75})$$

$$R^2 = 0,19$$

$$\text{mini-CBR(Hmn)} = -3,33\text{c}' - 0,03\text{Pi} + 0,012\text{d}' - 0,02\text{e}' - 0,43(\#0,42) - 0,10(\#0,074) + 0,14(\#0,005) + 62,98 \quad (\text{A.76})$$

$$R^2 = 0,26$$

$$\text{mini-CBR(Hmn)} = -3,30c' - 0,03P_i + 0,01d' + 0,94e' - 0,94V_a - 0,45(\#0,42) - 0,06(\#0,074) + 0,14(\#0,005) + 63,95 \quad (\text{A.77})$$

$$R^2 = 0,27$$

$$\text{mini-CBR(Hmn)} = -0,12c' - 3,41P_i - 0,03d' + 0,01e' + 0,11CA + 0,22(\#0,42) - 0,45(\#0,074) - 0,08(\#0,005) + 65,15 \quad (\text{A.78})$$

$$R^2 = 0,26$$

$$\text{mini-CBR(Hmn)} = -2,58c' - 0,04P_i + 0,02d' + 3,00e' - 0,96V_a + 18,57 \quad (\text{A.79})$$

$$R^2 = 0,22$$

onde:

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(Hmi): mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, em %;

mini-CBR(24hi): mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, em %;

V_a : valor de azul, em 10^{-3} g/g;

CA: coeficiente de atividade em 10^{-3} g/g%;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm.

p_n : massa específica seca máxima na energia normal, em g/cm^3 ;

W_{oi} : umidade ótima na energia intermediária, em %;

W_{on} : umidade ótima na energia normal, em %;

c' : traduz a argilosidade do solo;

P_i : perda de massa por imersão, em %;

d' : inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e' : expressa o caráter laterítico do solo;

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %;

croma: traduz a saturação ou a intensidade do colorido de um solo;

valor: traduz a tonalidade mais clara ou mais escura da cor de um solo.

A.6. MINI-CBR NA UMIDADE DE MOLDAGEM OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

As expressões A.80 a A.96 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar o mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária em função de outras propriedades.

$$\text{mini-CBR(Hmi)} = 1,07\text{mini-CBR(Hmn)} + 1,02\text{mini-CBR(24hn)} + 5,58 \quad (\text{A.80})$$

$$R^2 = 0,54$$

$$\text{mini-CBR(Hmi)} = 1,06\text{mini-CBR(Hmn)} + 1,03\text{mini-CBR(24hn)} - 0,07V_a + 5,71 \quad (\text{A.81})$$

$$R^2 = 0,54$$

$$\text{mini-CBR(Hmi)} = 0,99\text{mini-CBR(Hmn)} + 1,05\text{mini-CBR(24hn)} - 1,89V_a - 0,61(\#0,42) + 0,26(\#0,074) - 0,15(\#0,005) + 61,46 \quad (\text{A.82})$$

$$R^2 = 0,57$$

$$\text{mini-CBR(Hmi)} = 1,66\text{mini-CBR(Hmn)} + 0,20V_a + 5,86 \quad (\text{A.83})$$

$$R^2 = 0,51$$

$$\text{mini-CBR(Hmi)} = 1,58\text{mini-CBR(Hmn)} - 1,72V_a - 0,66(\#0,42) + 0,21(\#0,074) - 0,06(\#0,005) + 66,94 \quad (\text{A.84})$$

$$R^2 = 0,54$$

$$\text{mini-CBR(Hmi)} = 1,61\text{mini-CBR(Hmn)} - 0,59(\#0,42) + 0,12(\#0,074) - 0,06(\#0,005) + 60,91 \quad (\text{A.85})$$

$$R^2 = 0,53$$

$$\text{mini-CBR(Hmi)} = -3,10\text{Va} - 1,61(\#0,42) + 0,07(\#0,074) + 0,24(\#0,005) + 180,74 \quad (\text{A.86})$$

$$R^2 = 0,15$$

$$\text{mini-CBR(Hmi)} = -1,53(\#0,42) - 0,09(\#0,074) + 0,26(\#0,005) - 173,70 \quad (\text{A.87})$$

$$R^2 = 0,11$$

$$\text{mini-CBR(Hmi)} = 0,76\text{Won} + 52,20\text{pn} - 75,81 \quad (\text{A.88})$$

$$R^2 = 0,15$$

$$\text{mini-CBR(Hmi)} = 0,67\text{Woi} + 45,02\text{pi} - 65,09 \quad (\text{A.89})$$

$$R^2 = 0,20$$

$$\text{mini-CBR(Hmi)} = -0,45\text{Woi} + 38,95\text{pi} - 1,23(\#0,42) + 0,22(\#0,074) + 0,19(\#0,005) + 65,39 \quad (\text{A.90})$$

$$R^2 = 0,29$$

$$\text{mini-CBR(Hmi)} = -0,37\text{Woi} + 38,09\text{pi} - 0,81\text{Va} - 1,25(\#0,42) + 0,24(\#0,074) + 0,18(\#0,005) + 68,59 \quad (\text{A.91})$$

$$R^2 = 0,29$$

$$\text{mini-CBR(Hmi)} = -4,20\text{c}^* - 0,07\text{Pi} + 0,02\text{d}^* + 0,83\text{e}^* + 40,54 \quad (\text{A.92})$$

$$R^2 = 0,15$$

$$\text{mini-CBR(Hmi)} = -2,19\text{c}^* - 0,06\text{Pi} + 0,002\text{d}^* - 1,77\text{e}^* - 1,22(\#0,42) - 0,05(\#0,074) + 0,06(\#0,005) + 158,94 \quad (\text{A.93})$$

$$R^2 = 0,21$$

$$\text{mini-CBR(Hmi)} = -2,07c' - 0,07P_i - 0,0007d' + 1,64e' - 3,32V_a - 1,29(\#0,42) + 0,12(\#0,074) + 0,035(\#0,005) + 162,39 \quad (\text{A.94})$$

$$R^2 = 0,25$$

$$\text{mini-CBR(Hmi)} = -0,46c' - 2,46P_i - 0,06d' - 0,002e' - 0,88CA - 1,28(\#0,42) + 0,05(\#0,074) + 0,08(\#0,005) + 167,10 \quad (\text{A.95})$$

$$R^2 = 0,22$$

$$\text{mini-CBR(Hmi)} = -0,89c' - 0,09P_i + 0,01d' + 5,31e' - 2,54V_a + 37,62 \quad (\text{A.96})$$

$$R^2 = 0,19$$

onde:

mini-CBR(Hmi): mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, em %;

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %;

Won: umidade ótima na energia normal, em %;

pn: massa específica aparente seca máxima na energia normal, em g/cm^3 ;

Woi: umidade ótima na energia intermediária, em %;

pi: massa específica seca máxima na energia intermediária, em g/cm^3 ;

Va: valor de azul, em 10^{-3} g/g ;

CA: coeficiente de atividade em $10^{-3} \text{ g/g}\%$;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm;

c': traduz a argilosidade do solo;

Pi: perda de massa por imersão, em %;

d': inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e': expressa o caráter laterítico do solo;

croma: traduz a saturação ou a intensidade do colorido de um solo;

valor: traduz a tonalidade mais clara ou mais escura da cor de um solo.

A.7. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA NORMAL

As expressões A.97 a A.112 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar o mini-CBR após 24h de imersão obtido na umidade ótima na energia normal em função de outras propriedades.

$$\text{mini-CBR}(24\text{hn}) = 0,12\text{mini-CBR}(\text{Hmi}) + 0,16\text{mini-CBR}(24\text{hi}) + 2,22 \quad (\text{A.97})$$

$$R^2 = 0,51$$

$$\text{mini-CBR}(24\text{hn}) = 0,12\text{mini-CBR}(\text{Hmi}) + 0,16\text{mini-CBR}(24\text{hi}) + 0,04V_a + 2,15 \quad (\text{A.98})$$

$$R^2 = 0,51$$

$$\text{mini-CBR}(24\text{hn}) = 0,13\text{mini-CBR}(\text{Hmi}) + 0,12\text{mini-CBR}(24\text{hi}) + 0,29V_a - 0,04(\#0,42) - 0,10(\#0,074) + 0,12(\#0,005) - 6,75 \quad (\text{A.99})$$

$$R^2 = 0,55$$

$$\text{mini-CBR}(24\text{hn}) = 0,29\text{mini-CBR}(24\text{hi}) + 0,17V_a - 0,05(\#0,42) - 0,09(\#0,074) + 0,10(\#0,005) + 9,01 \quad (\text{A.100})$$

$$R^2 = 0,49$$

$$\text{mini-CBR}(24\text{hn}) = -0,32V_a - 0,38(\#0,42) - 0,09(\#0,074) + 0,19(\#0,005) + 45,28 \quad (\text{A.101})$$

$$R^2 = 0,17$$

$$\text{mini-CBR}(24\text{hn}) = -0,37(\#0,42) - 0,11(\#0,074) + 0,19(\#0,005) + 44,56 \quad (\text{A.102})$$

$$R^2 = 0,17$$

$$\text{mini-CBR}(24\text{hn}) = 13,02W_{oi} + 0,23p_i - 19,03 \quad (\text{A.103})$$

$$R^2 = 0,19$$

$$\begin{aligned} \text{mini-CBR}(24\text{hn}) = 0,05W_{on} + 16,87p_n + 0,13V_a - 0,33(\#0,42) - 0,04(\#0,074) + \\ 0,16(\#0,005) + 6,91 \end{aligned} \quad (\text{A.104})$$

$$R^2 = 0,35$$

$$\text{mini-CBR}(24\text{hn}) = 2,84\text{mini-CBR}(24\text{hi}) + 0,31V_a + 2,84 \quad (\text{A.105})$$

$$R^2 = 0,46$$

$$\text{mini-CBR}(24\text{hn}) = 0,31W_{on} + 19,56p_n - 31,03 \quad (\text{A.106})$$

$$R^2 = 0,24$$

$$\begin{aligned} \text{mini-CBR}(24\text{hn}) = 0,06W_{on} + 16,75p_n - 0,03(\#0,42) - 0,04(\#0,074) + 0,15(\#0,005) \\ + 7,21 \end{aligned} \quad (\text{A.107})$$

$$R^2 = 0,34$$

$$\text{mini-CBR}(24\text{hn}) = -1,64c' - 0,02P_i + 0,02d' + 2,29e' + 9,53 \quad (\text{A.108})$$

$$R^2 = 0,15$$

$$\begin{aligned} \text{mini-CBR}(24\text{hn}) = -2,05c' - 0,02P_i + 0,01d' + 0,82e' - 0,30(\#0,42) - 0,1(\#0,074) + \\ 0,17(\#0,005) + 39,70 \end{aligned} \quad (\text{A.109})$$

$$R^2 = 0,24$$

$$\begin{aligned} \text{mini-CBR}(24\text{hn}) = -2,04c' - 0,02P_i + 0,01d' + 1,18e' - 0,35V_a - 0,30(\#0,42) - \\ 0,08(\#0,074) + 0,16(\#0,005) + 40,07 \end{aligned} \quad (\text{A.110})$$

$$R^2 = 0,25$$

$$\begin{aligned} \text{mini-CBR}(24\text{hn}) = 0,002c' - 2,05P_i - 0,02d' + 0,01e' + 0,81CA - 0,29(\#0,42) - \\ 0,10(\#0,074) - 0,17(\#0,005) - 39,67 \end{aligned} \quad (\text{A.111})$$

$$R^2 = 0,24$$

$$\text{mini-CBR}(24\text{hn}) = -1,11c' - 0,03P_i + 0,02d' + 3,00e' - 0,41V_a + 9,06 \quad (\text{A.112})$$

$$R^2 = 0,16$$

onde:

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %;

mini-CBR(Hmi): mini-CBR na umidade de moldagem obtido na umidade ótima na energia intermediária, em %;

mini-CBR(24hi): mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, em %;

Won: umidade ótima na energia normal, em %;

pn: massa específica seca máxima na energia normal, em g/cm^3 ;

Woi: umidade ótima na energia intermediária, em %;

pi: massa específica seca máxima na energia intermediária, em g/cm^3 ;

Va: valor de azul, em 10^{-3} g/g ;

CA: coeficiente de atividade em $10^{-3} \text{ g/g}\%$;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm;

c': traduz a argilosidade do solo;

Pi: perda de massa por imersão, em %;

d': inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e': expressa o caráter laterítico do solo;

A.8. MINI-CBR APÓS 24 H DE IMERSÃO OBTIDO NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

As expressões A.113 a A.127 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar o mini-CBR após 24h de imersão obtido na umidade ótima na energia intermediária em função de outras propriedades.

$$\text{mini-CBR}(24\text{hi}) = 0,43\text{mini-CBR}(\text{Hmn}) + 0,96\text{mini-CBR}(24\text{hn}) + 4,59 \quad (\text{A.113})$$

$$R^2 = 0,50$$

$$\text{mini-CBR}(24\text{hi}) = 0,44\text{mini-CBR}(\text{Hmn}) + 0,94\text{mini-CBR}(24\text{hn}) + 0,28\text{Va} + 4,06 \quad (\text{A.114})$$

$$R^2 = 0,50$$

$$\text{mini-CBR}(24\text{hi}) = 1,48\text{mini-CBR}(24\text{hn}) + 0,07\text{Va} + 5,91 \quad (\text{A.115})$$

$$R^2 = 0,50$$

$$\text{mini-CBR}(24\text{hi}) = 1,32\text{mini-CBR}(24\text{hn}) - 1,27\text{Va} - 0,63(\#0,42) + 0,09(\#0,074) + 0,05(\#0,005) + 65,35 \quad (\text{A.116})$$

$$R^2 = 0,51$$

$$\text{mini-CBR}(24\text{hi}) = - 1,69\text{Va} - 1,13(\#0,42) - 0,04(\#0,074) + 0,30(\#0,005) - 125,05 \quad (\text{A.117})$$

$$R^2 = 0,21$$

$$\text{mini-CBR}(24\text{hi}) = - 1,09(\#0,42) - 0,13(\#0,074) + 0,30(\#0,005) + 121,22 \quad (\text{A.118})$$

$$R^2 = 0,18$$

$$\text{mini-CBR}(24\text{hi}) = 0,53\text{Won} + 29,61\text{pn} - 42,16 \quad (\text{A.119})$$

$$R^2 = 0,12$$

$$\text{mini-CBR}(24\text{hi}) = 0,46\text{Woi} + 23,93\text{pi} - 32,61 \quad (\text{A.120})$$

$$R^2 = 0,14$$

$$\text{mini-CBR}(24\text{hi}) = -0,43\text{Woi} + 16,91\text{pi} - 0,99(\#0,42) + 0,04(\#0,074) + 0,30(\#0,005) + 77,78 \quad (\text{A.121})$$

$$R^2 = 0,28$$

$$\text{mini-CBR}(24\text{hi}) = -0,39\text{Woi} + 16,46\text{pi} - 0,42\text{Va} - 0,99(\#0,42) + 0,06(\#0,074) + 0,30(\#0,005) + 79,45 \quad (\text{A.122})$$

$$R^2 = 0,28$$

$$\text{mini-CBR}(24\text{hi}) = -2,37\text{c}' - 0,03\text{Pi} + 0,02\text{d}' - 1,94\text{e}' + 26,53 \quad (\text{A.123})$$

$$R^2 = 0,14$$

$$\text{mini-CBR}(24\text{hi}) = -4,51\text{c}' - 0,01\text{Pi} + 0,003\text{d}' - 6,61\text{e}' - 0,97(\#0,42) - 0,09(\#0,074) + 0,29(\#0,005) + 123,43 \quad (\text{A.124})$$

$$R^2 = 0,25$$

$$\text{mini-CBR}(24\text{hi}) = -4,45\text{c}' - 0,02\text{Pi} + 0,004\text{d}' - 4,93\text{e}' - 1,63\text{Va} - 1,01(\#0,42) - 0,01(\#0,074) + 0,28(\#0,005) + 125,13 \quad (\text{A.125})$$

$$R^2 = 0,27$$

$$\text{mini-CBR}(24\text{hi}) = -0,26\text{c}' - 4,67\text{Pi} - 0,01\text{d}' + 0,003\text{e}' - 6,10\text{CA} - 1,01(\#0,42) - 0,04(\#0,074) + 0,21(\#0,005) + 128,04 \quad (\text{A.126})$$

$$R^2 = 0,26$$

$$\text{mini-CBR}(24\text{hi}) = -1,3\text{c}' - 0,04\text{Pi} + 0,02\text{d}' - 0,50\text{e}' - 0,82\text{Va} + 25,59 \quad (\text{A.127})$$

$$R^2 = 0,15$$

onde:

mini-CBR(24hi): mini-CBR após 24 h de imersão obtido na umidade ótima na energia intermediária, em %;

mini-CBR(Hmn): mini-CBR na umidade de moldagem obtido na umidade ótima na energia normal, em %;

mini-CBR(24hn): mini-CBR após 24 h de imersão obtido na umidade ótima na energia normal, em %;

Won: umidade ótima na energia normal, em %;

pn: massa específica aparente seca máxima na energia normal, em g/cm^3 ;

Woi: umidade ótima na energia intermediária, em %;

ρ_i : massa específica aparente seca máxima na energia intermediária, em g/cm^3 ;

Va: valor de azul, em 10^{-3} g/g ;

CA: coeficiente de atividade, em $10^{-3} \text{ g/g}\%$;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm.

c' : traduz a argilosidade do solo;

Pi: perda de massa por imersão, em %;

d' : inclinação do ramo seco da curva de compactação, em $\text{kg/m}^3\%$;

e' : expressa o caráter laterítico do solo.

A.9. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL

As expressões A.128 a A.137 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a expansão obtida na umidade ótima na energia normal em função de outras propriedades.

$$E_n = 0,42E_i + 0,03V_a + 0,013 \quad (\text{A.128})$$

$$R^2 = 0,30$$

$$E_n = 0,41E_i + 0,04V_a - 0,003(\#0,42) + 0,002(\#0,074) - 0,005(\#0,005) + 0,27 \quad (\text{A.129})$$

$$R^2 = 0,33$$

$$E_n = 0,46E_i - 0,003(\#0,42) + 0,004(\#0,074) - 0,005(\#0,005) + 0,29 \quad (\text{A.130})$$

$$R^2 = 0,30$$

$$E_n = -0,001W_{on} + 0,05V_a + 0,04 \quad (\text{A.131})$$

$$R^2 = 0,0$$

$$E_n = -0,01(\#0,42) + 0,006(\#0,074) - 0,005(\#0,005) + 0,87 \quad (\text{A.132})$$

$$R^2 = 0,13$$



$$E_n = 0,01W_{on} + 0,003CA - 0,01(\#0,42) + 0,004(\#0,074) - 0,005(\#0,005) + 0,61 \quad (\text{A.133})$$

$$R^2 = 0,16$$

$$E_n = 0,005W_{on} + 0,05Va - 0,01(\#0,42) + 0,003(\#0,074) - 0,006(\#0,005) + 0,66 \quad (\text{A.134})$$

$$R^2 = 0,21$$

$$E_n = 0,01W_{on} - 0,007(\#0,42) + 0,004(\#0,074) - 0,01(\#0,005) + 0,66 \quad (\text{A.135})$$

$$R^2 = 0,16$$

$$E_n = 0,05W_{on} - 0,001CA + 0,66 \quad (\text{A.136})$$

$$R^2 = 0,16$$

$$E_n = - 0,009(\#0,42) + 0,006(\#0,074) - 0,005(\#0,005) + 0,87 \quad (\text{A.137})$$

$$R^2 = 0,13$$

onde:

E_n : expansão obtida na umidade ótima na energia normal, em %;

E_i : expansão obtida na umidade ótima na energia intermediária, em %;

W_{on} : umidade ótima na energia normal, em %;

V_a : valor de azul, em 10^{-3} g/g;

CA : coeficiente de atividade, em 10^{-3} g/g%;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm.

A.10. EXPANSÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

As expressões A.138 a A.147 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a expansão obtida na umidade ótima na energia intermediária em função de outras propriedades.

$$E_i = 0,40E_n + 0,04V_a + 0,02 \quad (\text{A.138})$$

$$R^2 = 0,33$$

$$E_i = 0,40E_n + 0,02V_a - 0,009(\#0,42) + 0,001(\#0,074) + 0,0005(\#0,005) + 0,84 \quad (\text{A.139})$$

$$R^2 = 0,36$$

$$E_i = 0,05V_a - 0,01(\#0,42) + 0,002(\#0,074) - 0,002(\#0,005) + 1,13 \quad (\text{A.140})$$

$$R^2 = 0,23$$

$$E_i = + 0,005(\#0,074) - 0,002(\#0,005) - 14,05 \quad (\text{A.141})$$

$$R^2 = 0,18$$

$$E_i = 0,003W_{oi} + 0,04V_a + 0,01 \quad (\text{A.142})$$

$$R^2 = 0,20$$

$$E_i = 0,01W_{oi} + 0,007CA - 0,07 \quad (\text{A.143})$$

$$R^2 = 0,18$$

$$E_i = 0,01W_{oi} - 0,01(\#0,42) + 0,003(\#0,074) - 0,003(\#0,005) - 1,10 \quad (\text{A.144})$$

$$R^2 = 0,20$$

$$E_i = 0,004W_{oi} + 0,04V_a - 0,01(\#0,42) + 0,002(\#0,074) - 0,002(\#0,005) + 1,08 \quad (\text{A.145})$$

$$R^2 = 0,23$$

$$E_i = 0,007W_{on} + 0,006CA - 0,01(\#0,42) + 0,002(\#0,074) - 0,001(\#0,005) + 1,00 \quad (\text{A.146})$$

$$R^2 = 0,22$$

$$E_i = - 0,01(\#0,42) + 0,005(\#0,074) - 0,002(\#0,005) + 1,24 \quad (\text{A.147})$$

$$R^2 = 0,18$$

onde:

Ei: expansão obtida na umidade ótima na energia intermediária, em %;

En: expansão obtida na umidade ótima na energia normal, em %;

Won: umidade ótima na energia normal, em %;

Va: valor de azul, em 10^{-3} g/g;

CA: coeficiente de atividade, em 10^{-3} g/g%;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm.

A.11. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA NORMAL

As expressões A.148 a A.157 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a expansão obtida na umidade ótima na energia normal em função de outras propriedades.

$$C_n = 0,21V_a + 0,009(\#0,005) + 0,03 \quad (\text{A.148})$$

$$R^2 = 0,64$$

$$C_n = 0,20V_a + 0,005(\#0,42) + 0,003(\#0,074) + 0,006(\#0,005) - 0,52 \quad (\text{A.149})$$

$$R^2 = 0,63$$

$$C_n = 0,55C_i + 0,004(\#0,42) + 0,006(\#0,074) + 0,003(\#0,005) - 0,35 \quad (\text{A.150})$$

$$R^2 = 0,69$$

$$C_n = -0,003(\#0,42) + 0,014(\#0,074) + 0,005(\#0,005) - 0,07 \quad (\text{A.151})$$

$$R^2 = 0,52$$

$$C_n = 0,04W_{on} + 0,15V_a - 0,20 \quad (\text{A.152})$$

$$R^2 = 0,68$$

$$C_n = 0,06W_{on} + 0,013CA - 0,42 \quad (\text{A.153})$$

$$R^2 = 0,63$$

$$C_n = 0,05W_{on} + 0,01(\#0,42) + 0,004(\#0,074) - 0,001(\#0,005) - 1,13 \quad (\text{A.154})$$

$$R^2 = 0,63$$

$$C_n = 0,04W_{on} + 0,15V_a + 0,01(\#0,42) - 0,001(\#0,074) + 0,001(\#0,005) - 1,16 \quad (\text{A.155})$$

$$R^2 = 0,68$$

$$C_n = 0,05W_{on} + 0,017V_a + 0,01(\#0,42) + 0,001(\#0,074) + 0,004(\#0,005) - 1,39 \quad (\text{A.156})$$

$$R^2 = 0,64$$

$$C_n = -3,3 \cdot 10^{-5}(\#0,42) + 0,014(\#0,074) + 0,005(\#0,005) - 0,08 \quad (\text{A.157})$$

$$R^2 = 0,53$$

onde:

C_n : contração obtida na umidade ótima na energia normal, em %;

C_i : contração obtida na umidade ótima na energia intermediária, em %;

W_{on} : umidade ótima na energia normal, em %;

V_a : valor de azul, em 10^{-3} g/g;

CA : coeficiente de atividade, em 10^{-3} g/g%;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm.

A.12. CONTRAÇÃO OBTIDA NA UMIDADE ÓTIMA NA ENERGIA INTERMEDIÁRIA

As expressões A.158 a A.169 apresentam, respectivamente, as equações de regressão e os coeficientes de determinação (R^2) para determinar a expansão obtida na umidade ótima na energia intermediária em função de outras propriedades.

$$C_i = 0,14V_a + 0,004(\#0,42) + 0,006(\#0,074) + 0,0002(\#0,005) - 0,05 \quad (\text{A.158})$$

$$R^2 = 0,56$$

$$C_i = 0,18V_a + 0,01(\#0,005) - 0,01 \quad (\text{A.159})$$

$$R^2 = 0,55$$

$$C_i = 0,62C_n + 0,09V_a + 0,02 \quad (\text{A.160})$$

$$R^2 = 0,65$$

$$C_i = 0,55C_n + 0,043V_a - 0,005(\#0,42) + 0,005(\#0,074) + 0,0009(\#0,005) + 0,45 \quad (\text{A.161})$$

$$R^2 = 0,67$$

$$C_i = 0,15V_a - 0,002(\#0,42) + 0,006(\#0,074) + 0,004(\#0,005) + 0,16 \quad (\text{A.162})$$

$$R^2 = 0,56$$

$$C_i = -0,007(\#0,42) + 0,015(\#0,074) + 0,03(\#0,005) + 0,51 \quad (\text{A.163})$$

$$R^2 = 0,49$$

$$C_i = 0,04W_{oi} + 0,12V_a - 0,18 \quad (\text{A.164})$$

$$R^2 = 0,59$$

$$C_i = 0,06W_{oi} + 0,009CA - 0,32 \quad (\text{A.165})$$

$$R^2 = 0,56$$

$$C_i = 0,05W_{oi} - 0,0003(\#0,42) + 0,006(\#0,074) - 0,003(\#0,005) - 0,25 \quad (\text{A.166})$$

$$R^2 = 0,57$$

$$C_i = 0,04W_{oi} + 0,11V_a + 0,001(\#0,42) + 0,003(\#0,074) - 0,001(\#0,005) - 0,30 \quad (\text{A.167})$$

$$R^2 = 0,59$$

$$C_i = 0,046W_{oi} + 0,01CA + 0,00077(\#0,42) + 0,0047(\#0,074) + 0,0006(\#0,005) - 0,40 \quad (\text{A.168})$$

$$R^2 = 0,57$$

$$C_i = -0,007(\#0,42) + 0,01(\#0,074) + 0,003(\#0,005) + 0,51 \quad (\text{A.169})$$

$$R^2 = 0,50$$

C_i : contração obtida na umidade ótima na energia intermediária, em %;

C_n : contração obtida na umidade ótima na energia normal, em %;

W_{oi} : umidade ótima na energia intermediária, em %;

V_a : valor de azul, em 10^{-3} g/g;

CA : coeficiente de atividade, em 10^{-3} g/g%;

(#2,00), (#0,42), (#0,074), (#0,005): frações de solos passadas nas peneiras de abertura nominal de, respectivamente, 2,00 mm, 0,42 mm, 0,074mm e 0,005 mm.