

EDGAR RICARDO FERREIRA

**PROCEDIMENTOS AUTOMÁTICOS PARA APOIO NA
AVALIAÇÃO DE PAVIMENTOS COM O USO
DE IMAGENS DIGITAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2010

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

F383p
2010

Ferreira, Edgar Ricardo, 1957-

Procedimentos automáticos para apoio na avaliação de pavimentos com o uso de imagens digitais / Edgar Ricardo Ferreira. – Viçosa, MG, 2010.

xxii, 239f. : il. (algumas col.) ; 29cm.

Inclui apêndices.

Orientador: Carlos Antônio Oliveira Vieira.

Tese (doutorado) - Universidade Federal de Viçosa.

Referências bibliográficas: f. 199-207.

1. Rodovias - Administração. 2. Pavimentos de asfalto - Avaliação. 3. Rodovias - Manutenção e reparos.
4. Processamento de imagens - Técnicas digitais.
5. Sensoriamento remoto. 6. Radar de penetração no solo.
7. Sistemas de reconhecimento de padrões. I. Universidade Federal de Viçosa. II. Título.

CDD 22.ed. 625.8

EDGAR RICARDO FERREIRA

**PROCEDIMENTOS AUTOMÁTICOS PARA APOIO NA
AVALIAÇÃO DE PAVIMENTOS COM O USO
DE IMAGENS DIGITAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Doctor Scientiae*.


Aprovada: 09 de fevereiro de 2010



Prof. Carlos Alexandre B. de Carvalho
(Co-orientador)




Prof. José Marinaldo Gleriani
(Co-orientador)



Prof. Aluir Porfírio Dal'Poz



Prof. Geraldo Luciano de O. Marques



Prof. Carlos Antônio Oliveira Vieira
(Orientador)

Dedico esse trabalho a quatro pessoas muito importantes na minha vida e que sempre me incentivaram: minha esposa Cristina, minhas filhas Edna e Débora e meu filho Fábio.

*“O valor das coisas não
está no tempo que elas duram, mas
na intensidade com que aconte-
cem. Por isso existem momentos
inesquecíveis, coisas inexplicáveis
e pessoas incomparáveis”*

Fernando Pessoa

AGRADECIMENTOS

À minha esposa Cristina, por estar sempre ao meu lado, me ajudando e apoiando nestes 40 anos de convivência e a meus 3 filhos, orgulhos de minha vida.

Ao meu orientador, prof. Carlos Antônio O. Vieira, pela paciência, pelos incentivos, pelas idéias, pelas incansáveis conversas ao longo dos anos do programa de doutorado e, principalmente, pela amizade.

Aos professores co-orientadores: Carlos Alexandre B. de Carvalho, José Marinaldo Gleriani e Maria Lúcia Calijuri por se mostrarem sempre dispostos a ajudar.

Aos colegas de convivência nesse período em Viçosa: prof. Joel Gripp Júnior (UFV), prof. Júlio César de Oliveira (UFV), prof. Moisés Ferreira Costa (UFV), prof. Adelson (CEFET - Vitória), prof. Vicente Paulo Soares (UFV), prof. Agostinho Lopes de Souza (UFV), prof. Jairo R. Silva (CEFET - Ouro Preto) e sua esposa, profa. Cecília F. Andrade.

Aos colegas de trânsito Juiz de Fora-Viçosa, prof. Walcyr Duarte Nascimento (CTU), prof. Luiz Fernando Miranda (CEFET - Ouro Preto) e o Eng. Marcos Amado (PJF), pelos incansáveis momentos que passamos juntos dentro de um carro, no período de crédito do programa de doutorado.

Ao curso de Pós-Graduação em Engenharia Civil da Universidade Federal de Viçosa - UFV, em especial seu coordenador, prof. Eduardo Antônio G. Marques, pela forma simples e descomplicada de lidar com as competências de sua função.

Aos funcionários da Pós-Graduação e Graduação em Engenharia Civil da UFV.

Ao Núcleo de Geoprocessamento prof. Celestino Aspiazu - NUGEO, pelo uso das instalações e equipamentos.

Ao Colégio Técnico Universitário - CTU, por ter-me possibilitado e facilitado a conclusão do doutorado.

Aos colegas do Departamento de Construções Cíveis do CTU, pela sensibilidade de permitir o meu afastamento durante o período de doutorado.

Ao reitor da Universidade Federal de Juiz de Fora - UFJF, prof. Henrique Duque de Miranda Chaves Filho, e vice-reitor da UFJF, prof. José Luiz Rezende Pereira, pelo apoio institucional.

Ao Programa de Incentivo à Inovação - PII da UFJF, pela ajuda financeira e compra de materiais, equipamentos e do *software* HDM-4.

À FAPEMIG, pela compra de materiais e equipamentos, em especial o espectrorradiômetro.

À CAPES pela bolsa de doutorado concedida.

Ao Departamento de Solos da UFV, nas pessoas dos professores Elpídio Inácio Fernandes Filho e Carlos Ernesto G. R. Schaefer pelo empréstimo do GPR.

Ao Instituto Nacional de Pesquisas Espaciais - INPE, na pessoa da profa. Elisabete Caria Moraes, pelo empréstimo do espectrorradiômetro.

Ao Departamento de Geologia da Universidade Federal de Minas Gerais - UFMG, na pessoa do prof. Paulo Roberto A. Aranha, pela ajuda nas atividades de campo com o GPR e o processamento de seus dados.

Ao colega de pós-graduação Sandro Henrique de Faria, pela ajuda nos experimentos com o GPR.

À minha sobrinha Flávia Carvalho Faria, pela revisão ortográfica desse trabalho.

Às demais pessoas e entidades que, direta ou indiretamente, contribuíram para este trabalho e, mesmo não sendo citadas nominalmente, não significam que foram menos importantes.

A todos, meu sincero “muito obrigado”.

BIOGRAFIA

EDGAR RICARDO FERREIRA, filho de José Ferreira Filho e Zita Pinto Ferreira, nasceu em 21 de setembro de 1957, na cidade de Ubá, MG.

Graduou-se em Engenharia Civil em julho de 1981, pela Universidade Federal de Juiz de Fora - UFJF, em Juiz de Fora - MG.

Em 1990, terminou o mestrado em Ciências Geodésicas, opção Fotogrametria, na Universidade Federal do Paraná, em Curitiba - PR.

Em 2003, terminou a especialização em Transporte e Trânsito, na Fundação Mineira para a Educação e Cultura - FUMEC, em Belo Horizonte - MG.

Em agosto de 2005, iniciou o doutorado em Engenharia Civil, área de concentração Mecânica dos Pavimentos, pela Universidade Federal de Viçosa - UFV, em Viçosa - MG.

Desde abril de 1980 é professor do Colégio Técnico Universitário da Universidade Federal de Juiz de Fora, atual Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais (IF Semge MG). Lotado no Departamento de Construções Cíveis, lecionou várias disciplinas para os cursos técnicos de Edificações, Estradas e Transporte Rodoviário.

Atualmente, continua como professor dos cursos técnicos em Edificações e Transporte Rodoviário e está como diretor do Núcleo de Inovações e Transferência de Tecnologia - NITTEC do IF Semge MG.

SUMÁRIO

LISTA DE FIGURAS.....	xii
LISTA DE TABELAS.....	xvi
LISTA DE SIGLAS E LEGENDAS.....	xvii
RESUMO.....	xix
ABSTRACT	xxi
CAPÍTULO 1.....	1
INTRODUÇÃO.....	1
1.1. CONSIDERAÇÕES INICIAIS	1
1.2. CARACTERIZAÇÃO DO PROBLEMA	3
1.3. JUSTIFICATIVA E RELEVÂNCIA DESSA TESE	4
1.4. HIPÓTESES DA TESE.....	6
1.5. OBJETIVOS GERAIS E ESPECÍFICOS	6
1.5.1. OBJETIVOS GERAIS	6
1.5.2. OBJETIVOS ESPECÍFICOS.....	7
1.6. ESTRUTURA DESSA TESE	7
CAPÍTULO 2.....	10
LEVANTAMENTO DE DEFEITOS SUPERFICIAIS EM PAVIMENTOS ASFÁLTICOS.....	10
2.1. INTRODUÇÃO	10
2.1.1. A MALHA RODOVIÁRIA BRASILEIRA.....	13
2.1.1.1. ALGUNS DADOS RELEVANTES	13
2.1.1.2. A GERÊNCIA DE PAVIMENTOS	15
2.1.2. DEFEITOS SUPERFICIAIS	18
2.2. LEVANTAMENTO MANUAL DOS DEFEITOS.....	25
2.3. LEVANTAMENTO DOS DEFEITOS COM O USO DE IMAGENS	28
2.3.1. IMAGENS EM NÍVEL ORBITAL	28
2.3.2. IMAGENS EM NÍVEL SUB-ORBITAL.....	30
2.3.3. IMAGENS EM NÍVEL TERRESTRE	30
2.4. RESUMO DO CAPÍTULO	33
CAPÍTULO 3.....	34
CURVAS ESPECTRAIS DE PADRÕES DO PAVIMENTO ASFÁLTICO	34
3.1. INTRODUÇÃO	34
3.1.1. UMA ABORDAGEM SOBRE A REFLECTÂNCIA.....	39
3.1.2. ESQUEMA DE UM RADIÔMETRO	43
3.2. REVISÃO DA LITERATURA	44
3.3. MATERIAIS E MÉTODOS.....	46
3.3.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO	46
3.3.2. MATERIAL	47

3.3.3. OBTENÇÃO DOS DADOS DE CAMPO	48
3.3.4. METODOLOGIA DO TRABALHO.....	49
3.3.5. RESULTADOS E DISCUSSÕES.....	50
3.3.5.1. ANÁLISE DE CURVAS ESPECTRAIS DE 350 A 2.500 NM PARA A DISCRIMINAÇÃO DE PADRÕES DE PAVIMENTOS ASFÁLTICOS	50
3.3.5.2. CURVAS ESPECTRAIS DO PAVIMENTO ASFÁLTICO NO INTERVALO DE 400 A 755 NM.....	52
3.4. RESUMO DO CAPÍTULO	54
CAPÍTULO 4.....	55
DISCRIMINAÇÃO DE DEFEITOS SUPERFICIAIS EM PAVIMENTO ASFÁLTICO COM O USO DE IMAGENS MULTIESPECTRAIS.....	55
4.1. INTRODUÇÃO	55
4.2. DESCRIÇÃO DO OBJETO	56
4.3. EXTRAÇÃO DE CARACTERÍSTICAS	56
4.4. REGRA DE DECISÃO.....	57
4.4.1. CLASSIFICADORES MULTIESPECTRAIS	58
4.4.1.1. CLASSIFICAÇÃO SUPERVISIONADA	59
4.4.1.2. CLASSIFICAÇÃO NÃO-SUPERVISIONADA	61
4.4.1.3. CLASSIFICADOR MAXVER.....	62
4.4.1.4. REDES NEURAIS ARTIFICIAIS.....	64
4.5. AVALIAÇÃO DO MODELO	73
4.6. MATERIAIS E MÉTODOS.....	73
4.6.1. PRIMEIRO EXPERIMENTO	74
4.6.1.1. CONTEXTUALIZAÇÃO E OBJETIVO	74
4.6.1.2. DESCRIÇÃO DA ÁREA DO EXPERIMENTO	74
4.6.1.3. METODOLOGIA DO TRABALHO	74
4.6.1.4. RESULTADOS E DISCUSSÕES	77
4.6.1.5. CONCLUSÕES	79
4.6.2. SEGUNDO EXPERIMENTO.....	80
4.6.2.1. CONTEXTUALIZAÇÃO E OBJETIVO	80
4.6.2.2. METODOLOGIA DO TRABALHO	80
4.6.2.3. RESULTADOS E DISCUSSÕES	84
4.6.2.4. CONCLUSÕES	86
4.7. RESUMO DO CAPÍTULO	87
CAPÍTULO 5.....	89
DISCRIMINAÇÃO DE DEFEITOS SUPERFICIAIS EM PAVIMENTO ASFÁLTICO ATRAVÉS DA TEXTURA	89
5.1. INTRODUÇÃO	89
5.2. MÉTODOS PARA DISCRIMINAÇÃO DA TEXTURA	93
5.2.1. MÉTODOS ESTRUTURAIS OU GEOMÉTRICOS	93
5.2.2. MÉTODOS ESTATÍSTICOS	93
5.2.3. MÉTODOS DE MULTIRRESOLUÇÃO	94
5.2.4. MÉTODOS DAS TRANSFORMADAS	94

5.2.5. MÉTODOS BASEADOS EM MODELOS	94
5.3. QUANTIFICAÇÃO DA TEXTURA	95
5.3.1. MEDIDA BASEADA EM ESTATÍSTICA DE 1ª ORDEM	95
5.3.2. MEDIDA BASEADA EM ESTATÍSTICA DE 2ª ORDEM	95
5.3.3. MEDIDA BASEADA EM ESTATÍSTICA DE ORDEM SUPERIOR.....	95
5.4. EXTRAÇÃO DA TEXTURA UTILIZANDO A TRANSFORMADA WAVELET	96
5.4.1. TRANSFORMADA WAVELET CONTÍNUA E TRANSFORMADA WAVELET DISCRETA.....	98
5.4.2. DECOMPOSIÇÃO DE UMA IMAGEM	98
5.5. DISCRIMINAÇÃO DA TEXTURA UTILIZANDO MORFOLOGIA MATEMÁTICA	102
5.5.1. OPERAÇÃO DE DILATAÇÃO	103
5.5.2. OPERAÇÃO DE EROÇÃO	104
5.5.3. ABERTURA	105
5.5.4. FECHAMENTO	105
5.5.5. OPERADORES MORFOLÓGICOS EM IMAGENS BINÁRIAS.....	106
5.5.5.1. EXTRAÇÃO DE BORDAS.....	106
5.5.5.2. EXTRAÇÃO DE COMPONENTES CONECTADOS.....	107
5.5.5.3. ESQUELETIZAÇÃO DE REGIÕES.....	107
5.5.6. OPERADORES MORFOLÓGICOS EM IMAGENS MONOCROMÁTICAS	108
5.6. MATERIAIS E MÉTODOS.....	108
5.6.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO	109
5.6.2. MATERIAL	109
5.6.3. OBTENÇÃO DOS DADOS DE CAMPO	109
5.6.4. METODOLOGIA DOS TRABALHOS.....	111
5.6.4.1. EXPERIMENTO 1 - USO DA TRANSFORMADA WAVELET.....	111
5.6.4.2. EXPERIMENTO 2 - USO DE MORFOLOGIA MATEMÁTICA.....	121
5.7. RESUMO DO CAPÍTULO	125
CAPITULO 6	126
DISCRIMINAÇÃO DAS CAMADAS DO PAVIMENTO ATRAVÉS DA TEXTURA	126
6.1. INTRODUÇÃO	126
6.2. REVISÃO DA LITERATURA	131
6.3. ENTENDENDO O PRINCÍPIO DE FUNCIONAMENTO DO GPR.....	136
6.3.1. A VELOCIDADE DAS ONDAS.....	137
6.3.2. A REFLEXÃO DAS ONDAS	139
6.3.3. POLARIZAÇÃO ELÉTRICA DAS ONDAS	140
6.4. O MÉTODO GPR	140
6.4.1. AQUISIÇÃO DOS DADOS.....	140
6.4.2. ESCOLHA DA FREQUÊNCIA DE OPERAÇÃO	143
6.4.3. INFLUÊNCIA DAS CAMADAS DA SUBSUPERFÍCIE	143
6.4.4. RUÍDOS	144
6.4.5. CONFIGURAÇÃO DAS ANTENAS	145
6.5. PROCESSAMENTO DOS DADOS	147

6.5.1. PROCESSAMENTO BÁSICO	148
6.5.2. PROCESSAMENTO AVANÇADO	149
6.6. MATERIAIS E MÉTODOS.....	150
6.6.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO	150
6.6.2. MATERIAL	151
6.6.3. OBTENÇÃO DOS DADOS DE CAMPO	152
6.6.3.1. DEFINIÇÃO DOS PARÂMETROS	152
6.6.3.2. CALIBRAÇÃO DO HODÔMETRO	152
6.6.3.3. LEVANTAMENTO DOS PERFIS SUBSUPERFICIAIS	152
6.6.3.4. PROCESSAMENTO DOS DADOS	152
6.6.4. METODOLOGIA DO TRABALHO.....	153
6.6.5. RESULTADOS E DISCUSSÕES.....	155
6.6.6. CONCLUSÕES.....	158
6.7. RESUMO DO CAPÍTULO	159
CAPITULO 7	160
SISTEMA DE GERÊNCIA DE PAVIMENTO	160
7.1. INTRODUÇÃO	160
7.2. REVISÃO DA LITERATURA	163
7.3. SISTEMA DE GERÊNCIA DE PAVIMENTO	166
7.3.1. NÍVEIS DE GERÊNCIA DE UM SGP	167
7.3.1.1. GERÊNCIA EM NÍVEL DE REDE	168
7.3.1.2. GERÊNCIA EM NÍVEL DE PROJETO	168
7.3.2. COMPONENTES PRINCIPAIS DE UM SGP.....	168
7.3.2.1. BASE DE DADOS	168
7.3.2.2. AVALIAÇÃO DE PAVIMENTO	169
7.3.2.3. MODELOS DE PREVISÃO DE DESEMPENHO	169
7.3.2.4. CRITÉRIOS DE DECISÃO	172
7.3.2.5. ANÁLISE TÉCNICA.....	173
7.3.2.6. ANÁLISE ECONÔMICA	173
7.4. O SOFTWARE HDM-4	174
7.4.1. BREVE HISTÓRICO.....	175
7.4.2. ALGUMAS CARACTERÍSTICAS DO HDM-4	176
7.4.3. ARQUITETURA DO HDM-4.....	177
7.4.3.1. MÓDULO GERENCIAMENTO DE DADOS (DATA MANAGERS)	177
7.4.3.2. MÓDULO FERRAMENTAS DE ANÁLISE (ANALYSIS TOOLS).....	178
7.4.3.3. MÓDULO DE MODELOS (MODEL).....	180
7.4.3.4. MÓDULO DE IMPORTAÇÃO E EXPORTAÇÃO DE DADOS	181
7.5. INTEGRAÇÃO DOS DADOS	182
7.5.1. DEFEITOS SUPERFICIAIS MODELADOS NO HDM-4.....	183
7.5.1.1. UNIDADES DOS DADOS	184
7.5.1.2. ENTRADA DE DADOS.....	185
7.5.2. DADOS OBTIDOS COM AS IMAGENS DIGITAIS E USADOS NO HDM-4	188

7.6. RESUMO DO CAPÍTULO	189
CAPITULO 8	190
CONCLUSÕES E RECOMENDAÇÕES	190
8.1. RESUMO E CONCLUSÕES	190
8.2. RECOMENDAÇÕES PARA PESQUISAS FUTURAS.....	193
BIBLIOGRAFIA CITADA.....	199
BIBLIOGRAFIA CONSULTADA.....	207
APÊNDICE A	208
PASSO-A-PASSO PARA CLASSIFICAÇÃO SUPERVISIONADA UTILIZANDO O SOFTWARE IDRISI ANDES	208
A.1 PASSO 1	208
A.2 PASSO 2	209
A.3 PASSO 3	212
APÊNDICE B	216
ROTINAS DESENVOLVIDAS NO SOFTWARE MATLAB.....	216
APÊNDICE C	222
PASSO-A-PASSO PARA PROCESSAMENTO DE IMAGENS DO GPR COM O USO DO SOFTWARE GRADIX.....	222
APÊNDICE D	229
EXEMPLO DE APLICAÇÃO USANDO O SOFTWARE HDM-4	229
D.1 CRIAR UM NOVO PROJETO (NEW PROJECT).....	230
D.2 DEFINIR OS DETALHES DO PROJETO (DEFINE PROJECT DETAILS).....	231
D.3 ESPECIFICAR ALTERNATIVAS (SPECIFY ALTERNATIVES)	234
D.4 ANÁLISE DE PROJETOS (ANALYSE PROJECTS)	236
D.4.1 RUN SETUP	236
D.4.2 SENSITIVITY	237
D.4.3 RUN ANALYSYS	238
D.5 ANÁLISE MULTICRITÉRIOS (MULTI CRITERIA ANALYSIS).....	238
D.6 RELATÓRIOS GERADOS (GENERATE REPORTS)	239

LISTA DE FIGURAS

CAPITULO 2

Figura 2.1 - Seção transversal típica de um pavimento flexível	10
Figura 2.2 - Fases da vida de um pavimento flexível (gráfico da banheira).....	12
Figura 2.3 - Classificação geral das rodovias pavimentadas segundo a extensão analisada	14
Figura 2.4 - Classificação da qualidade do pavimento analisado.....	15
Figura 2.5 - Imagens dos defeitos, classificadas de acordo com o Manual do SHRP	22
Figura 2.6 - Imagens dos defeitos, classificadas de acordo com o Manual do SHRP	24
Figura 2.7 - Planilhas utilizadas no levantamento de defeitos superficiais	25
Figura 2.8 - Exemplo de mapeamento dos defeitos	26
Figura 2.9 - Veículo avaliador, Sistema Hawkeye	27
Figura 2.10 - Desenvolvimento histórico da aquisição de imagens para uso na identificação de defeitos	31
Figura 2.11 - Sistema desenvolvido por Barella	32
Figura 2.12 - Sistema ARAN, da Fugro Roadware.....	33

CAPITULO 3

Figura 3.1 - Partes componentes de um sistema sensor e possíveis resultados	35
Figura 3.2 - Esquema de utilização de uma câmera terrestre de varredura linear	36
Figura 3.3 - Imagem analógica e sua correspondente imagem digital em 8 bits	36
Figura 3.4 – Nomenclatura dos diferentes tipos de imagens	38
Figura 3.5 - Diferentes tipos de imagens:	39
Figura 3.6 - Interação entre radiação incidente e objeto	40
Figura 3.7 - Curva de reflectância de vários revestimentos	42
Figura 3.8 - Esquema de um radiômetro e montagem no campo	43
Figura 3.9 - Vista aérea das instalações e vias do INPE.....	47
Figura 3.10 - Espectrorradiômetro FieldSpec utilizado no experimento.....	48
Figura 3.11 - Curvas espectrais dos 4 padrões analisados.....	51
Figura 3.12 - Curvas espectrais obtidas por operação de diferença.....	51
Figura 3.13 - Curvas espectrais obtidas por operação de diferença.....	52
Figura 3.14 - Curvas de reflectância no intervalo de 400 a 755 nm para vários padrões de RA.....	53

CAPITULO 4

Figura 4.1 - Etapas de um sistema automático de reconhecimento de padrão	56
Figura 4.2 - Classificação de uma imagem de RA.....	57
Figura 4.3 - Imagem multiespectral de um RA composta de 3 bandas.....	58
Figura 4.4 - Etapas da classificação multiespectral (fase de treinamento)	59
Figura 4.5 - Etapas da classificação supervisionada.....	59
Figura 4.6 - Exemplo de limite de aceitação utilizando o classificador MaxVer	63
Figura 4.7 - Rede de neurônios	65
Figura 4.8 - Esquema típico de um neurônio artificial	66
Figura 4.9 - Arquiteturas típicas de modelos de RNAs.....	68

Figura 4.10 - Representação esquemática da arquitetura (topologia) de uma rede MLP	68
Figura 4.11 - Etapas da classificação supervisionada de uma rede MLP	69
Figura 4.12 - Parâmetros de análise em uma rede MLP	70
Figura 4.13 - Gráfico de erro de acordo com a interpolação	72
Figura 4.14 - Ponto de parada antecipada baseado na validação cruzada	73
Figura 4.15 - Caracterização das 4 classes informacionais em destaque na imagem	75
Figura 4.16 - Imagem pancromática e imagem multiespectral de uma mesma cena, mostrando a diferença na resolução espacial	76
Figura 4.17 - Gráfico do EMQ, denotando a não convergência da RNA	79
Figura 4.18 - Padrões de RA analisados	81
Figura 4.19 - Representação do re-escalonamento dos valores dos pixels	82
Figura 4.20 - Exemplo de uma imagem gerada e re-escalonada	83
Figura 4.21 - Imagem sintética gerada em uma banda e com os padrões analisados	83
Figura 4.22 - Imagem de referência utilizada	83
CAPITULO 5	
Figura 5.1 - Exemplos de textura	91
Figura 5.2 - Micro-textura e macro-textura em pavimento	92
Figura 5.3 - Análise de multirresolução	99
Figura 5.4 - Decomposição nível 1 da imagem Monalisa	101
Figura 5.5 - Exemplos de elementos estruturantes	103
Figura 5.6 - Operação de dilatação	104
Figura 5.7 - Operação de erosão	104
Figura 5.8 - Câmera Sony, DSC-H9	109
Figura 5.9 - Imagens utilizadas nos experimentos	110
Figura 5.10 - Etapas da metodologia utilizando multirresolução	112
Figura 5.11 - Determinação dos coeficientes Wavelets por bloco	113
Figura 5.12 - Vetor de características	113
Figura 5.13 - Extração de amostra da imagem para determinação dos limiares globais	115
Figura 5.14 - Resultados da classificação por limiarização global	119
Figura 5.15 - Etapas da metodologia utilizando operadores morfológicos	122
Figura 5.16 - Resultados da classificação utilizando morfologia matemática	124
CAPITULO 6	
Figura 6.1 - Princípio de funcionamento do GPR	127
Figura 6.2 - Interpretação do radargrama	128
Figura 6.3 - Representação da “pegada do GPR”	129
Figura 6.4 - Relação entre frequência, comprimento de onda, resolução e profundidade de penetração do GPR	130
Figura 6.5 - Radargrama, apresentando o contraste entre as camadas da subsuperfície	131
Figura 6.6 - Antenas GPR montadas em uma estrutura adaptada a um veículo que percorre a via férrea	133
Figura 6.7 - Modos de aquisição de dados pelo GPR	141
Figura 6.8 - Arranjo CMP	142

Figura 6.9 - Arranjo WARR e gráfico tempo x distância	142
Figura 6.10 - Exemplo de ruído associado à reflexão do sinal aéreo	144
Figura 6.11 - Efeito no radargrama causado pela indução entre as antenas e o WOW	145
Figura 6.12 - Possíveis orientações das antenas	146
Figura 6.13 - Mudanças na imagem devido à configuração das antenas	146
Figura 6.14 - Etapas do processamento de dados GPR	150
Figura 6.15 - Trecho do experimento - pista sul da via Dutra (RJ)	151
Figura 6.16 - Equipamento GPR utilizado no experimento	151
Figura 6.17 - Radargrama dos dois perfis levantados	153
Figura 6.18 - Identificação das classes informacionais do pavimento	153
Figura 6.19 – Separação das camadas do radargrama para facilitar a obtenção das amostras independentes	155
CAPITULO 7	
Figura 7.1 – Equipamentos modernos utilizados em rodovia para medir a aderência e a irregularidade	161
Figura 7.2 - Níveis de gerência de um SGP	167
Figura 7.3 - Arquitetura do HDM-4	177
Figura 7.4 - Escolha da rede no workspace	186
Figura 7.5 - Janela mostrando as seções da rede escolhida	186
Figura 7.6 - Janela para introduzir os dados sobre os defeitos	187
Figura 7.7 - Localização do arquivo Access do projeto	187
Figura 7.8 - Opções das tabelas do arquivo Rundata.mdb	188
APÊNDICE A	
Figura A.1 - Acesso ao comando MAKESIG, para assinatura das bandas	208
Figura A.2 - Tela do comando makesig	209
Figura A.3 - Relatório das assinaturas das 4 bandas utilizadas	209
Figura A.4 - Acesso ao comando maxlike, para a classificação MaxVer	210
Figura A.5 - Tela do comando maxlike e informações sobre a entrada e saída dos dados	210
Figura A.6 - Imagem classificada e rotulada	211
Figura A.7 - Acesso ao comando ERRMAT, para avaliação da imagem classificada	211
Figura A.8 - Tela do comando ERRMAT e informações sobre a entrada de dados	211
Figura A.9 - Acesso ao comando MAXLIKE, para a classificação usando RNA	212
Figura A.10 - Tela do comando MLP	213
APÊNDICE C	
Figura C.1 - Tela de abertura do GRADIX	222
Figura C.2 - Tela dos menus do GRADIX	222
Figura C.3 - Tela para criar o projeto e definir o nome que será dado aos arquivos importados para o GRADIX	223
Figura C.4 - Tela de importação de dados do GPR e escolha das características do dados de saída, que serão processados no GRADIX	223
Figura C.5 - Tela para escolher os arquivos que serão importados para o GRADIX	224
Figura C.6 - Tela sobre informação dos dados que serão importados para o GRADIX	224

Figura C.7 - Telas para leitura dos arquivos no GRADIX.....	225
Figura C.8 - Telas para visualização dos arquivos no GRADIX.....	225
Figura C.9 - Telas do comando declip	226
Figura C.10 - Telas do comando dewow	226
Figura C.11 - Telas do comando set time zero.....	227
Figura C.12 - Telas do comando windowtTraces	227
Figura C.13 - Telas do comando remove background	227
Figura C.14 - Tela mostrando o radargrama com as escalas horizontal e vertical iguais.....	228
APÊNDICE D	
Figura D.1 - Janela do HDM-4, para a escolha da ferramenta de análise	229
Figura D.2 - Janela do HDM-4 para nomear um novo projeto.....	231
Figura D.3 - Aba General	231
Figura D.4 - Aba Study Sections.....	232
Figura D.5 - Opções do botão View/Edit Section.....	233
Figura D.6 - Janelas de definição de dados sobre a frota de veículos.....	234
Figura D.7 - Janela Specify Alternatives, mostrando à direita as 2 seções analisadas	236
Figura D.8 - Janela da opção Analyse Projects, aba Setup Run.....	237
Figura D.9 - Janela da opção Analyse Projects, aba Sensitivity	237
Figura D.10 - Janela da opção Analyse Projects, aba Run Analysis	238
Figura D.11 - Janela da opção Multi Criteria Analysis, aba MCA Setup	238
Figura D.12 - Janela da opção Generate Reports.....	239
Figura D.13 - Exemplos dos relatórios apresentados pelo HDM-4	239

LISTA DE TABELAS

CAPITULO 2

Tabela 2.1 - Vias concessionadas (extensão por estado).....	17
Tabela 2.2 - Defeitos nos pavimentos flexíveis, segundo o SHRP	19
Tabela 2.3 - Algumas características dos sensores IKONOS II e QuickBird 2	29

CAPITULO 4

Tabela 4.1 - Exemplo de uma Matriz de Erros	60
Tabela 4.2 - Índices derivados da matriz de contingência.....	61
Tabela 4.3 - Valores do índice Kappa e correspondente desempenho da classificação	61
Tabela 4.4 - Principais funções de ativação (ou transferência).....	67
Tabela 4.5 - Matriz de erros com os resultados do classificador MaxVer	77
Tabela 4.6 - Matriz de erros com os resultados do classificador MaxVer	85
Tabela 4.7 - Matriz de erros com os resultados do classificador RNA.....	86

CAPITULO 5

Tabela 5.1 - Exemplo de características da amostra da imagem.....	115
Tabela 5.2 - Resultados da classificação MaxVer	116
Tabela 5.3 - Resultados da classificação RNA.....	118

CAPITULO 6

Tabela 6.1 - Algumas propriedades físicas importantes para o uso do GPR e seus valores para determinados materiais.	138
Tabela 6.2 - Valor do coeficiente de reflexão R entre 2 meios.....	139
Tabela 6.3 – Resultados da classificação MaxVer	155
Tabela 6.4 - Resultados da classificação RNA.....	156

CAPITULO 7

Tabela 7.1 – Informações sobre sistemas utilizados em alguns estados/órgão brasileiros.....	162
Tabela 7.2 - Modelos de previsão de desempenho.....	171
Tabela 7.3 - Defeitos de pavimentos modelados no HDM-4	183

LISTA DE SIGLAS E LEGENDAS

AASHTO	American Association of State Highway and Transportation Officials
ABCR	Associação Brasileira de Concessionárias de Rodovias
ABNT	Associação Brasileira de Normas Técnicas
ANTT	Agência Nacional de Transportes Terrestres
ARB	Associação Rodoviária Brasileira
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
BD	Banco de Dados
BID	Banco Interamericano de Desenvolvimento
BIRD	Banco Internacional para a Reconstrução e Desenvolvimento
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CBUQ	Concreto Betuminoso Usinado a Quente
CEFET	Centro Federal Tecnológico
CEPAL	Comissão Econômica para a América Latina e Caribe
CMP	<i>Common Middle Point</i> (Ponto Médio Comum)
CNT	Confederação Nacional de Transporte
CON	Contraste (descritor de Haralick)
COR	Correlação (descritor de Haralick)
CTU	Colégio Técnico Universitário
CWT	<i>Continuous Wavelet Transform</i> (Transformada Wavelet Contínua)
DER	Departamento de Estradas de Rodagem
DNER	Departamento Nacional de Estradas de Rodagem
DNIT	Departamento Nacional de Infra-estrutura de Transportes
DOT	Department of Transportation
DWT	<i>Discrete Wavelet Transform</i> (Transformada Wavelet Discreta)
EMQ	Erro Médio Quadrático
ENT	Entropia (descritor de Haralick)
EG	Exatidão Global (matriz de erros)
FAPEMIG	Fundação de Amparo à Pesquisa do Estado de Minas Gerais
FDP	Função Densidade de Probabilidade
FR	Fator de Reflectância
FHWA	Federal Highway Administration
FOV	Field of view
FWD	Falling Weight Deflectometer
GLCM	<i>Gray Level Cooccurrence Matrices</i> (Matriz de Co-ocorrência de níveis de cinza)
GPR	<i>Ground Penetration Radar</i> (Radar de Penetração no Solo)
HDM-4	Highway Development and Management
HDM-III	Highway Design and Maintenance Standards Model
HSS	Hyperspectral Scanner System
ICW	Índice dos Coeficientes <i>Wavelets</i>

INPE	Instituto Nacional de Pesquisas Espaciais
IRI	<i>International Roughness Index</i> (Índice de Irregularidade Internacional)
LTPP	Long-Term Pavement Performance
LVC	Levantamento Visual Contínuo
MaxVer	Algoritmo de Máxima Verossimilhança
MLP	<i>Multi Layer Perceptron</i> (Modelo de Múltiplas Camadas)
MT	Ministério dos Transportes
NC	Nível de cinza
NCHRP	National Cooperative Highway Research Program
NUGEO	Núcleo de Geoprocessamento da UFV
PAC	Programa de Aceleração do Crescimento
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
PDI	Processamento Digital de Imagem
PII	Programa de Incentivo à Inovação
PJF	Prefeitura de Juiz de Fora
PMS	<i>Pavement Management System</i> (Sistema de Gerência de Pavimento)
QMF	<i>Quadrature Mirror Filter</i> (Filtro Espelhado em Quadratura)
RA	Revestimento asfáltico
REM	Radiação eletromagnética
RNA	Redes Neurais Artificiais
RPE	Retropropagação do erro
SAC	Sistema de Administração da Conservação
SAM	Sistema de Administração da Manutenção
SGP	Sistema de Gerência de Pavimentos
SHRP	<i>Strategic Highway Research Program</i> (Programa Estratégico de Pesquisas Rodoviárias)
SI	Sistema Internacional
SIB	Sistema de Informações Básicas
SIG	Sistema de Informações Geográficas
SMA	Segundo Momento Angular (descritor de Haralick)
TER	Terminologia
TSD	Tratamento Superficial Duplo
UFJF	Universidade Federal de Juiz de Fora
UFMG	Universidade Federal de Minas Gerais
UFRJ	Universidade Federal do Rio de Janeiro
UFV	Universidade Federal de Viçosa
USP	Universidade de São Paulo
VN	Valor numérico do <i>pixel</i> (brilho)
WARR	<i>Wide Angle Reflection and Refraction</i> (Refração e Reflexão de Grande Ângulo)

RESUMO

FERREIRA, Edgar Ricardo, D.Sc., Universidade Federal de Viçosa, fevereiro de 2010. **Procedimentos automáticos para apoio na avaliação de pavimentos com o uso de imagens digitais.** Orientador: Carlos Antônio Oliveira Vieira, Co-orientadores: Carlos Alexandre Braz de Carvalho, José Marinaldo Gleriani e Maria Lúcia Calijuri.

Defeitos nas superfícies de pavimentos asfálticos são descontinuidades na pista de rolamento que afetam a segurança e o conforto do usuário, além de indicativos da necessidade de intervenções na via. O conhecimento das camadas do pavimento também é utilizado, juntamente com outros parâmetros estruturais, na análise de uma futura intervenção na via. Nesta tese, propõe-se o uso de imagens digitais do pavimento para detectar defeitos superficiais e para identificarr as camadas do pavimento. Quanto aos defeitos superficiais, a motivação é a possibilidade de se obter uma alternativa à técnica de levantamento tradicional de defeitos superficiais em uso no Brasil. Inicialmente, com o auxílio de um espectrorradiômetro, analisaram-se vários padrões correspondentes às condições da superfície do pavimento asfáltico, com o intuito de definir a faixa espectral que melhor discrimine aqueles padrões. Usando-se a técnica de reconhecimento automático de padrões, analisaram-se imagens orbitais de altíssima resolução e terrestre do pavimento asfáltico, empregando como regra de decisão o algoritmo da Máxima Verossimilhança e Redes Neurais Artificiais. Para a fase de discriminação das características, utilizou-se, nas imagens multiespectrais, dados espectrais e nas imagens monocromáticas, informações texturais. Para a determinação das camadas do pavimento usou-se um *Ground Penetration Radar* (GPR) na aquisição do perfil subsuperficial, obtendo-se uma imagem contínua das camadas do pavimento, e na classificação automática dessas imagens, usou-se, também, informações texturais para extrair características, o algoritmo da Máxima Verossimilhança e Redes Neurais Artificiais como regra de decisão. Posteriormente, com os dados obtidos na classificação sobre as imagens, ou seja, os defeitos superficiais do pavimento e suas camadas, verifica-se a possibilidade de usá-los em um Sistema de Gerência de Pavimentos (SGP) comercial. Os resultados da classificação com o uso de imagem orbital não foram animadores. No entanto,

quando se usou imagens terrestres para a classificação, os resultados foram surpreendentemente bons, indicando ser uma possibilidade bastante promissora. Na classificação da imagem subsuperficial do pavimento, os resultados foram razoavelmente satisfatórios, porém, inferiores ao da classificação dos defeitos. Quanto ao uso dos resultados obtidos na classificação das imagens e sua utilização como dados em um Sistema de Gerência de Pavimentos comercial, verificou-se, no sistema comercial analisado, não haver grandes dificuldades neste procedimento.

ABSTRACT

FERREIRA, Edgar Ricardo, D.Sc., Universidade Federal de Viçosa, February of 2010. **Automatic procedures to support the evaluation of pavements with the use of digital images.** Adviser: Carlos Antônio Oliveira Vieira, Co-Advisers: Carlos Alexandre Braz de Carvalho, José Marinaldo Gleriani and Maria Lúcia Calijuri.

Pavements surface distresses are discontinuities on the road which affect the safety and comfort of the user, as well as to possible needs for interventions on the road. The knowledge concerning the pavement layers also works, along with other structural parameters, analyzing further actions on the track. This thesis proposes the use of digital pavement images to detect surface distresses and to find out the pavement layers. This study aims a modern alternative against the current traditional technique of pavement surface defects inspections in Brazil. Firstly, under the spectroradiometer, it was analyzed several patterns relative to the conditions of the asphalt pavement surface in order to define the spectral range that best discriminate against those patterns. By the technique of automatic pattern recognition, it was analyzed the orbital images of high resolution and ground images from the asphalt pavement, using as a rule of decision the algorithm Maximum Likelihood and Artificial Neural Networks. Regarding the features discrimination it applied spectral data to the multispectral images and textural information to the monochrome images. It was worked with a Ground Penetration Radar (GPR) with the purpose of describing the pavement layers determination, thus it acquires the the subsurface profile, resulting in a continuous image of the pavement layers and the automatic classification of images, and in the automatic classification of those images, it was also used textural information to get characteristics as well as the algorithm of the Maximum Likelihood and Artificial Neural Networks as rule of decision. Subsequently, the data obtained in the classification of images, the pavement distresses and its layers in order, set out to ascertain the possibility of using them in a trade Pavement Management System (PMS). The results of classification using orbital images of high resolution were not encouraging, however, when it worked with ground images, the results were surprisingly

good, so it indicated a promising possibility in this way. In the classification of the subsurface image pavement, the results were so good so far pretty satisfactory, but lower than the defects classification. Regarding the use of results in the images classification and their use as data in a trade Management System Commercial, it had no major difficulties in this mentioned proceeding.

CAPÍTULO 1

INTRODUÇÃO

1.1. CONSIDERAÇÕES INICIAIS

Em 1954, o Brasil registrava 1.200 km de rodovias asfaltadas; em 1970, atingiu 50.590 km; em 1990 chegou a 148.121 km (ESTRADAS, 2008); e em 2006 a extensão era de 196.279 km, sendo assim distribuída, de acordo com a jurisdição (DNIT, 2008a): a) *rodovias federais* - 58.152 km; b) *rodovias estaduais coincidentes*¹ - 17.015,7 km; c) *rodovias estaduais não-coincidentes* - 98.376,5 km e d) *rodovias municipais* - 22.734,8 km.

O Brasil é um país em que as instalações de transportes estão concentradas no modo rodoviário, o qual contribui com mais de 90% da matriz de transporte de passageiros e 61% da matriz de transporte de cargas (CNT, 2007).

As rodovias devem ser entendidas prioritariamente como um patrimônio de todo o país e, como todo patrimônio, é necessário que haja um planejamento que considere sua manutenção e expansão, já que a demanda por este tipo de infra-estrutura de transportes é sempre crescente. A malha rodoviária pavimentada brasileira, constituída na sua maioria por pavimentos com revestimento asfáltico, é um patrimônio da ordem de R\$200 bilhões (PEDRAZZI, 2004).

É imprescindível ao Brasil, devido às suas características territoriais e a consolidação de seu desenvolvimento econômico, fazer a conservação e ampliação de sua malha rodoviária, garantindo o aumento do nível de serviço do transporte e a redução dos índices de acidentes (CNT, 2007).

¹ *Rodovias estaduais coincidentes* são rodovias construídas pelos estados sobre a diretriz de uma rodovia federal planejada, que apesar de listadas e codificadas como BR's, não se encontram sob jurisdição federal (DNIT, 2007).

O modal rodoviário interfere no desenvolvimento econômico, político e social de um país, pois é fundamental ao acesso de produtos e passageiros, propiciando a integração com os modais ferroviários, aeroviários, portuários e dutoviários.

Para manter esse gigantesco patrimônio, sob jurisdições diversas (federal, estadual, municipal e concedida²), é necessário haver ações de gerência, além de recursos financeiros disponíveis.

Segundo Aps *et al.* (1998), uma boa política de gestão de qualquer malha viária depende do fluxo contínuo de recursos necessários à implementação dos serviços de manutenção. Atrasos em obras resultam em custos muito superiores, podendo, por exemplo, em atrasos de seis meses a um ano, chegar a valores entre 400 e 500 % superiores ao orçamento inicial.

A partir do início da década de 1970, pesquisadores da área rodoviária introduziram o termo *Sistema de Gerência de Pavimentos* (SGP) para descrever o conjunto de ações relacionadas à seleção e priorização das atividades de manutenção e reabilitação de pavimentos, visando obter o melhor retorno possível para os recursos investidos, fornecendo pavimentos seguros, confortáveis e econômicos para os usuários.

Assim, gerenciar é composto por um conjunto de técnicas, habilidades e experiências adquiridas que, se empregadas de maneira sistemática, visam otimizar a relação entre diretrizes, restrições e a utilização dos recursos necessários para atingir os objetivos do empreendimento.

A Gerência Rodoviária é uma importante ferramenta do administrador para traçar a forma mais eficaz da aplicação dos recursos disponíveis nas rodovias que necessitam de recuperação em diversos níveis de intervenção, de

² *Rodovia Concedida* é aquela concedida por processo de transferência à iniciativa privada para exploração, cabendo à empresa vencedora da licitação, por prazo determinado, todos os trabalhos necessários para garantir as boas condições da estrada além de proporcionar serviços adequados aos seus usuários, através da cobrança de pedágio, revertendo, ao final do período, a rodovia ao poder concedente, em perfeito estado de condição física operacional (DNIT, 2007).

modo a responder às necessidades dos usuários dentro de um plano estratégico que garanta o alcance de um maior número de quilômetros recuperados (DNIT, 2008b).

O Programa de Aceleração do Crescimento (PAC) é um programa do governo federal, iniciado em 2007 e com término previsto para 2010 (programa quadrienal), com a finalidade de criar medidas para acelerar o crescimento do país, aumentando sua competitividade no mercado global. O programa prevê R\$ 503,90 bilhões em investimentos nas seguintes áreas: logística (rodovias, ferrovias, portos, aeroportos e hidrovias), energia e infra-estrutura-social e urbana. No caso das rodovias, vislumbra-se um investimento de R\$ 33,40 bilhões entre construção, adequação, duplicação e recuperação de 42 mil quilômetros de estradas (DNIT, 2008c).

1.2. CARACTERIZAÇÃO DO PROBLEMA

A superfície dos pavimentos deve ter a qualidade física que facilite o movimento dos veículos, oferecendo conforto e segurança. Defeitos na superfície dos pavimentos são desarranjos na pista de rolamento que contribuem para aumentar ou gerar desconforto e insegurança aos usuários da via e são indicadores de problemas no pavimento.

No Brasil, a avaliação das condições do pavimento através da análise dos defeitos superficiais é feita de duas formas: subjetiva e objetiva. As avaliações subjetivas são aquelas em que não se está buscando uma classificação exata dos defeitos e infere-se uma determinada nota, em uma escala pré-definida, com o fim de representar toda a condição do pavimento. Já as avaliações objetivas visam quantificar e qualificar os defeitos, individualmente ou em grupos, e posteriormente usar essas informações para medir o desempenho do pavimento.

Em nível mundial, onde se pratica uma avaliação funcional mais intensa, o que se verifica é uma substituição gradual dos métodos que utilizam a intervenção humana por métodos automatizados, assim como dos métodos de medição pontual por métodos de medições contínuas. Os avanços tecnológicos

nessa área têm introduzidos melhorias significativas para a engenharia rodoviária, não somente na agilidade da aquisição dos dados, como também na qualidade e processamento dos mesmos.

A situação brasileira referente ao levantamento dos defeitos superficiais de pavimentos ainda está bastante dependente da intervenção humana, seja com a presença do técnico na pista ou sob a forma de interpretação visual de uma filmagem da pista. O desenvolvimento de uma metodologia automática para o levantamento de defeitos superficiais viria ao encontro da tendência mundial, além de outros benefícios caracterizados pela substituição de procedimentos manuais pelo automático.

Agora, quando se analisam procedimentos de campo para se obter informações sobre as camadas do pavimento, esses também são bastante dependentes da intervenção humana e, ainda, são métodos invasivos e pontuais (sondagens diretas), além de interferirem diretamente no trânsito da via. Da mesma forma que nos defeitos superficiais, verifica-se uma mudança no panorama, isto é, a substituição de métodos manuais por procedimentos automáticos. A determinação da espessura das camadas é importante por ser um parâmetro utilizado na retroanálise³.

1.3. JUSTIFICATIVA E RELEVÂNCIA DESSA TESE

Desde o início do programa de doutorado, tinha-se por meta apresentar um trabalho de relevância científica e de inovação tecnológica com aplicação na engenharia rodoviária brasileira. Várias idéias foram abordadas. No momento que se idealizou a proposta de avaliar pavimentos com o uso de imagens digitais, e isso foi possível através de uma revisão bibliográfica profunda sobre o assunto, uma grande perspectiva foi criada, juntamente com uma avalanche de dúvidas. Seria possível uma tecnologia dessa natureza ter a sua aplicação aqui no Brasil? Haveria uma oportunidade de mostrar essa tecnologia a algum órgão de gestão rodoviária? Para sanar as dúvidas, pegou-

³ *Retroanálise* é um procedimento utilizado para o dimensionamento da camada de reforço do pavimento, baseado nos parâmetros defletoométricos e espessura das camadas.

se o projeto idealizado e marcou-se uma reunião para apresentá-lo na Agência Nacional de Transporte Terrestre (ANTT), em Brasília, em novembro de 2007. Na ANTT fomos recebidos pelo Eng. Wagner Garcia (na ocasião, como Diretor Técnico) e sua equipe e, após a apresentação do projeto, seguiram-se vários comentários favoráveis de sua equipe. A partir de então é que se teve plena certeza de que o tema era atual, empolgante, desafiador e inovador, com grandes possibilidades de colocação no mercado nacional.

A motivação para desenvolver esse trabalho, quanto ao tema “defeitos superficiais” é devida, principalmente, a três fatores. O primeiro deles é a expectativa da substituição de procedimentos manuais de levantamento de defeitos superficiais em pavimentos por um procedimento automático, mais rápido e menos subjetivo. O segundo fator é a relevância de que uma tecnologia desenvolvida no Brasil se enquadra melhor na nossa realidade e pode ter custo bem inferior daquela desenvolvida externamente e importada para o mercado brasileiro. Finalmente, o terceiro motivo é que se pretende, com o desenvolvimento dessa pesquisa, chamar a atenção para um segmento promissor, que é a automação de serviços relacionados às avaliações de pavimentos.

Já quanto ao tema “camadas do pavimento”, a motivação para elaboração dessa tese é desenvolver um procedimento de análise automático das imagens obtidas com o GPR, que seja confiável, em substituição à interpretação visual atualmente em uso.

Para se fazer a análise automática das imagens da superfície e da subsuperfície do pavimento, propõe-se, nesta tese, o desenvolvimento de um *Sistema Automático de Reconhecimento de Padrões*, que, segundo Vieira (2000), é dividido em quatro fases: Fase 1: *Descrição do objeto* - onde serão definidas as medidas ou as variáveis discriminatórias para representar computacionalmente os objetos de interesse; Fase 2: *Extração de características* - onde será relacionado um subconjunto de variáveis da lista de medidas ou de variáveis discriminatórias da etapa anterior, que melhor discriminará os objetos de interesse (eliminações daquelas que apresentam

redundâncias); Fase 3: *Regra de decisão* - onde serão definidos os classificadores; Fase 4: *Avaliação do modelo* - onde se verificará a precisão de detecção (ou identificação) do sistema automático de reconhecimento de padrões.

Agora, entrega-se esse trabalho à comunidade e, tem-se por expectativa, que todo o empenho ocorrido nos anos de doutorado do autor, em conjunto com a dedicação de vários colaboradores, venha a contribuir com profissionais e estudantes que lidam com questões da engenharia rodoviária brasileira.

1.4. HIPÓTESES DA TESE

Esta tese propõe comprovar três hipóteses.

Hipótese 1 - é possível realizar a detecção automática de defeitos na superfície dos pavimentos com revestimento asfáltico, utilizando técnicas de reconhecimento de padrões e através das características extraídas de imagens digitais multiespectrais e monocromáticas, obtidas respectivamente por: a) sensor orbital de altíssima resolução; b) sensor terrestre - câmera digital.

Hipótese 2 - é possível realizar a detecção automática das camadas dos pavimentos rodoviários, utilizando técnicas de reconhecimento de padrões e através das características extraídas de imagens digitais monocromáticas, obtidas com um GPR.

Hipótese 3 - é possível utilizar como dados em um SGP comercial os resultados obtidos na classificação das imagens superficiais e subsuperficiais do pavimento.

1.5. OBJETIVOS GERAIS E ESPECÍFICOS

1.5.1. OBJETIVOS GERAIS

Propõe-se, nesta tese, alcançar dois objetivos gerais. O primeiro objetivo

é a investigação e o desenvolvimento de metodologia(s) para fazer a análise automática das imagens digitais da superfície e subsuperfície do pavimento com revestimento asfáltico, utilizando técnicas de reconhecimento de padrões. O segundo objetivo é verificar a possibilidade de utilizar em um Sistema de Gerência de Pavimento (SGP) comercial os resultados obtidos no primeiro objetivo.

1.5.2. OBJETIVOS ESPECÍFICOS

Para atender aos objetivos gerais, os seguintes objetivos específicos foram delineados: a) fazer uma revisão sobre defeitos nas superfícies de pavimentos asfálticos; b) desenvolver experimentos no campo para obter as curvas espectrais das superfícies dos pavimentos asfálticos nas mais diversas condições de conservação, utilizando um espectrorradiômetro que opera na faixa do espectro eletromagnético de 400 a 2.500 nm; c) fazer a classificação automática das imagens da superfície do pavimento, através de classificadores paramétricos⁴ e não-paramétricos⁵; d) desenvolver experimentos no campo para obtenção de perfis subsuperficiais do pavimento asfáltico, utilizando um GPR, fazendo a classificação automática das imagens, também com o uso de classificadores paramétricos e não-paramétricos; e) escolher um SGP comercial e indicar o procedimento de como usar, neste sistema, os resultados obtidos nas classificações das imagens digitais.

1.6. ESTRUTURA DESSA TESE

Para atender aos objetivos propostos, essa tese está estruturada em oito capítulos e quatro apêndices.

No Capítulo 1, faz-se uma contextualização do problema e apresentam-se as hipóteses da tese a serem comprovadas.

⁴ *Classificadores paramétricos* são algoritmos em que se assume a forma da distribuição dos dados e cujo principal objetivo é estimar os parâmetros;

⁵ *Classificadores não-paramétricos* são algoritmos em que não se assume a forma da distribuição dos dados e cujo principal objetivo é obter uma partição do espaço de características.

No Capítulo 2, faz-se uma abordagem sobre defeitos superficiais em pavimentos asfálticos, sua classificação e procedimentos tradicionais para o levantamento dos defeitos.

O Capítulo 3 apresenta um estudo sobre curvas espectrais de vários padrões de defeitos superficiais em pavimentos asfálticos, analisando-se as características dessas curvas espectrais no sentido de determinar quais faixas espectrais melhor discriminam os defeitos superficiais.

O Capítulo 4 aborda o desenvolvimento de estratégias e procedimentos para o reconhecimento automático de padrões de defeitos em superfícies asfálticas com o uso de imagens multiespectrais.

O Capítulo 5 discorre sobre o estudo da textura em imagens como variável discriminatória utilizada em um sistema de reconhecimento de padrões, indicando uma metodologia para seleção das medidas texturais que discrimine os defeitos analisados.

O Capítulo 6 é sobre a análise de imagens da subsuperfície obtidas com o GPR, no sentido de obterem-se automaticamente as camadas do pavimento. Discorre-se, também, sobre a utilização e informações úteis a respeito do GPR e características das imagens obtidas.

O Capítulo 7 é sobre Sistema de Gerência de Pavimento, abordando-se aspectos gerais da gerência de pavimentos. Na sequência, avalia-se a possibilidade de usar os resultados da classificação sobre defeitos superficiais e camadas do pavimento em um *software* comercial de gerência de pavimentos.

No Capítulo 8 são abordadas as principais conclusões obtidas nesta tese e sugestões para trabalhos futuros.

Quanto aos apêndices, ficaram assim estruturados:

O Apêndice A apresenta um passo-a-passo para fazer a classificação

supervisionada utilizando o *software Idrisi Andes*, da *Clark University*. Aborda a classificação com o algoritmo MaxVer e RNA.

O Apêndice B apresenta uma rotina desenvolvida no *sotware MatLab* 7.0 para a extrair características da imagem e montar o vetor de características respectivos, sendo utilizado na classificação supervisionada das imagens do Capítulo 5 e Capítulo 6. A outra rotina apresentada é para fazer a classificação por limiarização, do vetor de características, sendo utilizada na classificação das imagens do Capítulo 5. Para entendimento das rotinas, há comentários ao longo das linhas de comando.

O Apêndice C apresenta um passo-a-passo para utilizar o *software GRADIX*, da *Interpex Limited*, desde a importação dos arquivos do GPR e passando pelas etapas do seu processamento.

O Apêndice D é sobre o *software HDM-4*. Desenvolve-se um exemplo de aplicação com o HDM-4, mostrando alguns aspectos de sua potencialidade.

CAPÍTULO 2

LEVANTAMENTO DE DEFEITOS SUPERFICIAIS EM PAVIMENTOS ASFÁLTICOS

O objetivo desse capítulo é discorrer sobre o levantamento de defeitos superficiais em pavimentos asfálticos. Para tanto, inicialmente, faz-se uma breve abordagem sobre o pavimento asfáltico e citam-se dados e aspectos relevantes da malha rodoviária brasileira. Em seguida, apresentam-se informações sobre defeitos superficiais e de como é feito o seu levantamento no Brasil. Finalmente, aborda-se o uso de imagens na detecção de defeitos superficiais em pavimentos.

2.1. INTRODUÇÃO

Pavimento é a estrutura construída sobre um terreno de fundação, de nome subleito, e que deverá resistir à ação das cargas dos veículos e às ações do tempo. O pavimento possui várias camadas, conforme mostrado na Figura 2.1. A camada superior, que fica em contato com os veículos, é denominada revestimento ou capa selante.




Figura 2.1 - Seção transversal típica de um pavimento flexível
Fonte: adaptado de Senço (1997)

Existem diferentes tipos de revestimentos, mas todos eles têm por finalidade proteger as camadas estruturais subjacentes a ele, aumentar a resistência à derrapagem, melhorar o conforto ao rolamento e resistir aos esforços causados pelo tráfego e pelo intemperismo.

Segundo o DNIT (2005), *“Os pavimentos são concebidos para durarem um determinado período. Durante cada um destes períodos ou ciclos de vida, o pavimento inicia numa condição ótima até alcançar uma condição ruim. O decréscimo da condição ou da serventia do pavimento ao longo do tempo é conhecido como deterioração do pavimento”*.

A deterioração de um pavimento, independente do seu tipo de revestimento, pode ser entendida como uma soma de fatores que tem sua origem nas eventuais deficiências de projeto, na execução da obra e no desempenho dos materiais utilizados na construção (MENEZES e MENEZES, 1996).

Posteriormente, ao longo do período de sua utilização, um pavimento fica submetido a várias solicitações que interferem diretamente na sua degradação. São elas: a) solicitação do tráfego, incluindo, principalmente, sobrecargas; b) alta incidência de repetição de cargas, determinando o processo de fadiga; c) altas pressões dos pneus, submetendo o pavimento a diversos esforços, como, compressão, cisalhamento e flexão; d) condições climáticas, como as precipitações pluviométricas e variações de temperatura (PEDRAZZI, 2004).

Dentre os diversos tipos de pavimentos rodoviários existentes, o pavimento flexível¹ é o mais utilizado no Brasil, motivo pelo qual esse trabalho está baseado na análise de defeitos de superfície dessa estrutura.

A Figura 2.2 caracteriza as fases da vida de um pavimento flexível, através do gráfico denominado “gráfico da banheira”. Os pavimentos flexíveis,

¹ *Pavimento flexível* é um tipo de pavimento asfáltico, cuja base é de material granular e a sub-base é de material granular ou solo.

após um período de consolidação (período em que as deflexões² diminuem), sem excesso de carga por eixo, apresentam um comportamento predominantemente elástico, isto é, cessado o carregamento, as deformações deixam de existir.




Figura 2.2 - Fases da vida de um pavimento flexível (gráfico da banheira)
Fonte: DNIT PRO 011/79

Esses pavimentos deterioram-se lentamente nos primeiros anos de uso (fase de consolidação e elástica), onde as deformações causadas pelo tráfego são inferiores às suportadas pelo mesmo. Assim, o pavimento funciona como uma estrutura elástica.

Com o passar do tempo e com a ação contínua do tráfego, o pavimento começa a perder sua elasticidade e, então, essa estrutura começa a exteriorizar os efeitos de fadiga, apresentando defeitos em sua superfície. Para minimizar essa “condição natural de deterioração do pavimento flexível”, deve-se fazer uma manutenção no pavimento, reabilitando-o para um novo ciclo de vida³.

O indicativo para se fazer a reabilitação do pavimento são as avaliações executadas sobre o mesmo, dividindo-se em *avaliação estrutural* e *avaliação funcional*.

² *Deflexões*, em pavimentação, são deslocamentos verticais recuperáveis, sendo um indicativo do comportamento elástico da estrutura. Elas caracterizam a resposta das camadas estruturais e do subleito ao carregamento;

³ *Ciclo de vida* de um pavimento é o período definido para que este inicie com uma condição ótima para o tráfego esperado/calculado até alcançar uma condição considerada ruim, devido à sua deterioração.

A *avaliação estrutural* de um pavimento é para medir o seu desempenho estrutural e refere-se às condições estruturais de suas camadas constituintes no sentido de suportar as cargas do tráfego e influências climáticas, sendo os ensaios defletoométricos os mais apropriados para a interpretação do comportamento estrutural do pavimento.

A *avaliação funcional* é para medir o desempenho funcional de um pavimento, estando associado às suas condições de superfície, isto é, à qualidade do revestimento, uma vez que este interfere no conforto e na segurança dos usuários que trafegam na via. Os defeitos analisados são: os defeitos superficiais, a irregularidade e a aderência.

Esta tese enfoca apenas os defeitos superficiais no pavimento. Os defeitos irregularidade e aderência, não fazem parte do escopo deste. Também será pesquisado um procedimento para a determinação das camadas do pavimento por meio indireto, ou seja, sem que haja uma intervenção no pavimento.

2.1.1. A MALHA RODOVIÁRIA BRASILEIRA

Para se entender sobre a importância do desenvolvimento de alguma metodologia que venha a contribuir na avaliação de um pavimento, segue algumas informações relevantes desse importante patrimônio, que é a malha rodoviária brasileira.

2.1.1.1. ALGUNS DADOS RELEVANTES

O Brasil possui a segunda maior malha rodoviária do mundo. Em novembro de 2006 sua extensão era de 1.769.159,5 km, com cerca de 11% pavimentada, ou seja, aproximadamente 196 mil km (DNIT, 2008a).

Quando se analisa a malha pavimentada, não se tem muito que comemorar. No tocante à extensão, um relatório realizado pela Comissão Econômica para a América Latina e Caribe (CEPAL) sobre a malha rodoviária pavimentada, aponta que o minúsculo Japão tem 790 mil km, a Itália, 300 mil km e a Austrália, 250 mil km. No Brasil, há 23 km de rodovias pavimentadas

por mil km² de território; já nos Estados Unidos, essa proporção é de 373 km/mil km² e na África do Sul, 44 km/mil km² (UOL, 2008).

Quando a análise, agora, recai sobre as condições dessa malha pavimentada, os números atuais são pouco animadores. Como exemplo, cita-se os 87.592 km de pavimentos pesquisados em 2007 pela Confederação Nacional de Transporte (CNT, 2007) e algumas de suas conclusões, a seguir:

(i) Avaliação do estado geral das rodovias

O estado geral das rodovias pavimentadas foi analisado considerando equitativamente os pesos das características do pavimento, sinalização e geometria de via.

Os resultados indicam situação geral desfavorável das rodovias brasileiras pavimentadas, assim: a) 64.699 km (73,9%) foram classificados como regular, ruim e péssimo; b) 22.893 km (26,1%) foram classificadas nas categorias ótimo e bom - Figura 2.3.





Figura 2.3 - Classificação geral das rodovias pavimentadas segundo a extensão analisada
Fonte: CNT (2007)

A avaliação qualitativa dos pavimentos mostra que 39.815 km (45,5%) são classificados como ótimo e bom. Os outros 47.777 km (54,5%) apresentam-se como regular, ruim e péssimo, onde 16.393 km da malha (equivalente a 18,7%) apresentam predominância de defeitos, como afundamentos, ondulações e buracos, ou encontram-se totalmente destruídos - Figura 2.4.



Pavimento	Extensão Total	
	km	%
Ótimo	34.132	39,0
Bom	5.683	6,5
Regular	31.384	35,8
Ruim	9.442	10,8
Péssimo	6.951	7,9
Total	87.592	100,0

Figura 2.4 - Classificação da qualidade do pavimento analisado
Fonte: CNT (2007)

(ii) Análise dos resultados da pesquisa

Os resultados referentes às variáveis qualitativas do pavimento, sinalização e geometria colaboram para a percepção das características e condições da malha rodoviária pesquisada. Foram avaliadas as seguintes características; pavimentação perfeita, trincas ou remendos, afundamentos, ondulações ou buracos, desgaste e pavimento totalmente destruído.

A pesquisa CNT (2007) constatou que, em relação à condição de superfície do pavimento, 53,2% (46.618 km) do total analisado foram considerados em situação favorável. Já os outros 46,7% (40.974 km) da extensão das rodovias, necessitam de algum tipo de intervenção, uma vez que o pavimento encontra-se desgastado, com trincas, remendos, buracos ou até mesmo totalmente destruído.

2.1.1.2. A GERÊNCIA DE PAVIMENTOS

Como manter esse patrimônio em condições de boa trafegabilidade? Através de ações de gerência. A gerência dos pavimentos brasileiros é desenvolvida pelo governo federal, através do DNIT, pelos governos estaduais, através dos Departamentos de Estradas de Rodagem (DER's) e pelas concessionárias rodoviárias.

Na seqüência são abordados os papéis do DNIT e das concessionárias na gestão de pavimentos.

(i) O papel do DNIT na gerência de pavimentos

O DNIT vem trabalhando dentro da filosofia de gerência de pavimento desde 1983, época que era conhecido como Departamento Nacional de Estradas de Rodagem (DNER).

Em 1992, foi desenvolvida a primeira versão de um SGP e em 2004, esse sistema passou a interagir diretamente com o *Highway Development and Management* - HDM-4⁴ (DNIT, 2008b e DNIT, 2008d).

Na área de planejamento, está sendo aplicado um conjunto de técnicas inerentes às Geotecnologias, visando o georreferenciamento da informação da infra-estrutura viária. Dentro dessa ótica, o DNIT está desenvolvendo um novo módulo do seu SGP, com a finalidade de relacionar os dados de levantamentos de campo às informações geográficas, possibilitando as análises espaciais. Citam-se as três principais ações em andamento: a) levantamento de campo para obtenção de dados técnicos para refinamento dos sistemas de planejamento; b) desenvolvimento e adequação dos sistemas de planejamento; c) levantamento de campo para obtenção de dados técnicos e insumos dos índices classificatórios das rodovias (DNIT, 2008b e DNIT, 2008d).

(ii) O papel das concessionárias na gerência de pavimentos

Concessão rodoviária é a transferência de um trecho de uma rodovia pública à iniciativa privada, por prazo determinado. A concessão se diferencia da privatização, pois esta última é a venda e transferência parcial ou total em caráter definitivo para uma ou mais empresas privadas, através da Bolsa de Valores.

A idéia que se passa na concessão rodoviária é de que o capital, antes reservado ao governo para investir em cuidados com a rodovia, agora é usado

⁴ HDM-4 é um software idealizado pelo corpo técnico do Banco Mundial, que define prioridades e cria cenários futuros de condições da infra-estrutura rodoviária para diversos níveis de investimento, gerando soluções de manutenção, construção e adequação da rede viária dentro de um programa plurianual, com a melhor relação custo/benefício.

em setores considerados essenciais para a população, como saúde, educação, saneamento, etc (CONCER, 2008).

Segundo a Agência Nacional de Transportes Terrestres (ANTT), o programa de Concessões de Rodovias Federais começou a ser implantado em 1995 com a licitação dos cinco trechos, totalizando 854,5 km, que haviam sido pedagiados diretamente pelo Ministério dos Transportes (MT). O pedágio garante o investimento e a manutenção constante necessária nas vias concessionadas.

As rodovias concessionadas possuem fluxo intenso de veículos (acima de 10 mil veículo/dia), o que provoca um desgaste rápido do pavimento que, sendo com recurso público, nem sempre conseguia ser recuperado. Além da manutenção, as concessionárias também prestam serviços de atendimento aos usuários, em especial, o atendimento médico de emergência em acidentes e o serviço de guincho para veículos avariados na rodovia (ANTT, 2008).

O Programa de Concessão de Rodovias Federais abrange 13.780,8 km de rodovias, desdobrado em concessões promovidas pelo Ministério dos Transportes, pelos governos estaduais, mediante delegações com base na Lei nº 9.277/96 e pela ANTT (ANTT, 2008).

Até o momento dessa consulta, ou seja, junho de 2008, tem-se 36 empresas concessionárias, divididas em 6 estados, explorando quase 10.000 km de rodovias, conforme Tabela 2.1.

Tabela 2.1 - Vias concessionadas (extensão por estado)

Fonte: ANTT (2008)

VIAS CONCESSIONADAS		
Estado	Quant.	Extensão (km)
RS	9	2.471,20
PR	6	2.543,75
SP	13	3.962,74
RJ	6	571,74
ES	1	67,50
BA	1	217,17
Total		9.834,10

De acordo com os seus contratos de concessão, essas empresas tiveram um investimento inicial previsto para infra-estrutura e melhoramentos, algo em torno de US\$14,5 bilhões, o que equivale a aproximadamente US\$1,50 milhão/km (ABCR, 2008).

Informações detalhadas sobre gerência de pavimentos são abordadas no Capítulo 7.

2.1.2. DEFEITOS SUPERFICIAIS

Quanto são os diferentes tipos de defeitos identificados na superfície de um pavimento asfáltico? Na literatura brasileira, as três publicações mais utilizadas sobre o assunto são: a) *Manual para Identificação de Defeitos de Revestimentos Asfálticos de Pavimentos* (DOMINGUES, 1993), onde considera 24 tipos de defeitos; b) *Catálogo dos Defeitos dos Revestimentos dos Pavimentos* (ARB, 1978), considerando 34 tipos de defeitos em pavimentos flexíveis; c) Norma DNIT 005/2003-TER, caracterizando 15 tipos de defeitos em pavimentos flexíveis.

Na literatura internacional tem-se a destacar: a) *Manual de Levantamento de Defeitos no Campo* utilizado no programa americano SHRP (*Strategic Highway Research Program* ou *Programa Estratégico de Pesquisas Rodoviárias*) - 1993, considerando 15 tipos de defeitos em pavimentos flexíveis; b) *AASHTO - Apêndice K: Defeitos Típicos* (AASHTO, 1986), onde se consideram 17 tipos de defeitos em pavimentos flexíveis, sendo 14 coincidentes com o SHRP.

Segundo Smith *et al.* (1987) e Castelo *et al.* (1990), os dois manuais publicados em português (ARB, 1978 e DOMINGUES, 1993) foram elaborados a partir das experiências francesa e americana e apresentam limitações e deficiências eliminadas nas diversas revisões por que passou o Manual do Programa SHRP. Por essa razão, o Manual do Programa SHRP é que tem sido mais largamente utilizado no Brasil. Com base nessa afirmação, o Manual do Programa SHRP é que será utilizado como referência para a classificação de

defeitos no presente trabalho.

No Manual do Programa SHRP, os 15 tipos de defeitos em pavimentos flexíveis são caracterizados, apresentando os níveis de severidade e o método de medição para cada tipo de defeito, conforme Tabela 2.2.

Tabela 2.2 - Defeitos nos pavimentos flexíveis, segundo o SHRP
Fonte: SHRP (1993)

DEFEITO	CARACTERÍSTICA	NÍVEIS DE SEVERIDADE	COMO MEDIR
1 TRINCAS POR FADIGA DO REVESTIMENTO	•áreas submetidas a cargas repetidas de tráfego •forma: “couro de crocodilo” ou “tela de galinheiro” •espaçamento inferior a 30 cm	•BAIXA: poucas trincas conectadas, sem erosão nos bordos e sem evidência de bombeamento •MÉDIA: trincas conectadas e bordos levemente erodidos, mas sem evidência de bombeamento •ALTA: trincas erodidas nos bordos, movimentação dos blocos quando submetidos ao tráfego e com evidência de bombeamento	•registrar área afetada (m²) para cada nível de severidade
2 TRINCAS EM BLOCOS	•trincas que dividem o pavimento em pedaços aproximadamente retangulares •tamanho dos blocos: 0,1 a 10 m²	•BAIXA: trincas com abertura média inferior a 6 mm ou seladas com material selante em boas condições •MÉDIA: trincas com abertura média entre 6 a 19 mm ou com trincas aleatórias adjacentes com severidade baixa •ALTA: trincas com abertura média superior a 19 mm ou trincas aleatórias adjacentes com severidade média alta	•registrar a área afetada (m²) para cada nível de severidade
3 TRINCAS NOS BORDOS	•apenas para pavimentos com acostamento não pavimentados •dentro de uma faixa de 60cm a partir da extremidade do pavimento	•BAIXA: sem perda de material ou despedaçamento •MÉDIA: perda de material e despedaçamento em até 10% da extensão afetada •ALTA: perda de material e despedaçamento em mais de 10% da extensão afetada	•registrar a extensão afetada (m) para cada nível de severidade.
4 TRINCAS LONGITUDINAIS	•trincas predominantemente paralelas ao eixo, podendo se localizar dentro ou fora das trilhas de roda	•BAIXA: trincas com abertura média inferior a 6mm ou seladas com material selante em boas condições •MÉDIA: trincas com abertura média entre 6 a 19 mm ou com trincas aleatória adjacentes com severidade baixa •ALTA: trincas com abertura média superior a 19 mm mas com trincas aleatórias adjacentes com severidade média alta	•registrar a extensão (m) das trincas longitudinais e os níveis de severidade correspondentes (nas trilhas de roda ou fora delas). •registrar a extensão com selante em boas condições.

Tabela 2.2 - Defeitos nos pavimentos flexíveis, segundo o SHRP (cont.)
Fonte: SHRP (1993)

DEFEITO	CARACTERÍSTICA	NÍVEIS DE SEVERIDADE	COMO MEDIR
5 TRINCAS POR REFLEXÃO	•reflexão de trincas ou juntas das camadas inferiores •recapeamento ou pavimentos novos (contração da base)	•BAIXA: trincas com abertura média BAIXA: inferior a 6 mm ou seladas com material selante em boas condições •MÉDIA: trincas com abertura média entre 6 a 19 mm ou com trincas aleatórias adjacentes com severidade baixa •ALTA: trincas com abertura média superior a 19 mm ou trincas com abertura média inferior a 19mm mas com trincas aleatória adjacentes com severidade média alta	•registrar em separado, as trincas transversais e longitudinais. •registrar o nº de trincas transversais. •registrar a extensão das trincas e os níveis de severidade •registrar a extensão com selante em boas condições
6 TRINCAS TRANS-VERSAIS	•trincas predominantemente perpendicular ao eixo •severidade de uma trinca: adotar a mais elevada, desde que represente pelo menos 10% da extensão	•BAIXA: trincas com abertura média inferior a 6 mm ou seladas com material selante em boas condições •MÉDIA: trincas com abertura média entre 6 a 19 mm ou com trincas aleatórias adjacentes com severidade baixa •ALTA: trincas com abertura média superior a 19 mm ou trincas com abertura média inferior a 19mm mas com trincas aleatórias adjacentes com severidade média alta	•registrar o nº de trincas, a extensão e os níveis de severidade correspondentes. •registrar a extensão com selante em boas condições.
7 REMENDOS	•porção da superfície do pavimento, maior que 0,1 m², removida e substituída ou material aplicado ao pavimento após a construção inicial	•Função da severidade dos defeitos apresentados pelo remendo	•registrar o nº de remendos e área afetada (m²) para cada nível de severidade.
8 PANELAS	•buracos resultantes de desintegração localizadas sob a ação do tráfego e em presença de água •fragmentação, causada por trincas por fadiga ou desgaste, e remoção localizada de partes do revestimentos	•BAIXA: profundidade menor que 25 mm •Média: profundidade entre 25 a 5 mm •ALTA: profundidade maior que 50 mm	•registrar o nº de painéis e a área afetada por cada nível de severidade.
9 DEFORMAÇÃO PERMANENTE	•depressão longitudinal nas trilhas de roda, em razão de densificação dos materiais ou ruptura por cisalhamento	•substituídos pelas medições da deformação permanente a cada 15 m.	•registrar a máxima deformação permanente nas trilhas de roda.

Tabela 2.2 - Defeitos nos pavimentos flexíveis, segundo o SHRP (cont.)
Fonte: SHRP (1993)

DEFEITO	CARACTERÍSTICA	NÍVEIS DE SEVERIDADE	COMO MEDIR
10 CORRU- GAÇÃO	•deformação plástica caracterizada pela formação de ondulações transversais na superfície do pavimento •Causada por esforços tangenciais (frenagem ou aceleração)	•associados aos defeitos sobre a qualidade do rolamento	•registrar o nº de ocorrências e a área afetada (m²)
11 EXSUDA- ÇÃO	•excesso de ligante betuminoso na superfície do pavimento	•BAIXA: mudança de coloração em relação ao restante do pavimento devido ao excesso de asfalto •MÉDIA: perda de textura superficial •ALTA: aparência brilhante; marcas de pneus evidentes em tempo quente; agregados cobertos pelo asfalto	•registrar a área afetada (m²) para cada nível de severidade.
12 AGREGA- DOS POLIDOS	•polimento (desgaste) dos agregados e do ligante betuminoso e exposição dos agregados graúdos •comprometimento da segurança: redução do coeficiente de atrito pneu-pavimento	•níveis de polimento podem ser associados à redução no coeficiente de atrito pneu-pavimento	•registrar a área afetada (m²).
13 DESGASTE	•perda de adesividade do ligante betuminoso e deslocamento dos agregados •envelhecimento, endurecimento, oxidação, volatilização, intemperização	•BAIXA: início do desgaste, com perda de agregados miúdos •MÉDIA: textura superficial torna-se áspera, com perda de agregados miúdos e de alguns graúdos •ALTA: textura superficial muito áspera, com perda de agregados graúdos	•registrar a área afetada (m²) para cada nível de severidade.
14 DESNÍVEL (DEGRAU) ENTRE PISTA E ACOSTA- MENTO	•diferença de elevação entre a faixa de tráfego e o acostamento: camadas sucessivas de revestimento asfáltico; erosão de acostamento não pavimentado; consolidação diferencial	•substituídos pelas medições do desnível	•registrar o desnível (mm) a cada 15 m, ao longo da interface pista-acostamento.
15 BOMBEA- MENTO	•saída de água pelas trincas do pavimento sob a ação das cargas do tráfego •identificado pela deposição à superfície de material carregado das camadas inferiores	•não aplicáveis porque o bombeamento depende do teor de umidade das camadas inferiores do pavimento	•registrar o nº de ocorrências e a extensão afetada (m²).
OBS:	1. Fotografar ou filmar defeito não considerado pelo manual; 2. Mapear EXSUDAÇÃO, AGREGADOS POLIDOS E DESGASTE apenas se ocorrerem em áreas localizadas; 3. Caso contrário, registrar localização, extensão e nível de severidade no espaço destinado aos comentários, no Mapa de Localização dos Defeitos.		

Para uma familiarização na identificação dos defeitos superficiais citados na Tabela 2.2, apresenta-se na Figura 2.5 os defeitos classificados segundo o grau de severidade (defeitos 1 a 7, 9, 11 e 13 da Tabela 2.2).

DEFEITO	SEVERIDADE BAIXA	SEVERIDADE MÉDIA	SEVERIDADE ALTA
1 TRINCAS POR FADIGA DO REVESTIMENTO			
2 TRINCAS EM BLOCOS			
3 TRINCAS NOS BORDOS			
4 TRINCAS LONGITUDINAIS			

Figura 2.5 - Imagens dos defeitos, classificadas de acordo com o Manual do SHRP
Fonte: SHRP (1993)

DEFEITO	SEVERIDADE BAIXA	SEVERIDADE MÉDIA	SEVERIDADE ALTA
5 TRINCAS POR REFLEXÃO			
6 TRINCAS TRANS- VERSAIS			
7 REMENDOS			
8 PANELAS			
9 DEFORMA- ÇÃO PERMA- NENTE			

Figura 2.5 - Imagens dos defeitos, classificadas de acordo com o Manual do SHRP (cont)
Fonte: SHRP (1993)

DEFEITO	SEVERIDADE BAIXA	SEVERIDADE MÉDIA	SEVERIDADE ALTA
11 EXSUDAÇÃO			
13 DESGASTE			

Figura 2.5 - Imagens dos defeitos, classificadas de acordo com o Manual do SHRP (cont)
Fonte: SHRP (1993)

A Figura 2.6 apresenta o restante das imagens de defeitos relacionados na Tabela 2.2 que não têm classificação pelo grau de severidade, que são os defeitos 10, 12, 14 e 15.

DEFEITO	IMAGEM	DEFEITO	IMAGEM
10 CORRUGAÇÃO		12 AGREGADOS POLIDOS	
DEFEITO	IMAGEM	DEFEITO	IMAGEM
14 DESNÍVEL (DEGRAU) ENTRE PISTA E ACOSTAMENTO		15 BOMBEAMENTO	

Figura 2.6 - Imagens dos defeitos, classificadas de acordo com o Manual do SHRP
Fonte: SHRP (1993)

2.2. LEVANTAMENTO MANUAL DOS DEFEITOS

No Brasil, o levantamento no campo dos defeitos superficiais do pavimento é realizado através de uma análise visual. Técnicos dentro de um veículo, trafegando na via a uma velocidade de 20 a 30 km/h, anotam em uma planilha específica as informações relativas aos defeitos (localização, classificação e severidade) ou, de outro modo, técnicos caminham pela via em trechos devidamente pré-selecionados, denominados *trechos homogêneos*⁵, também anotando em uma planilha específica as informações sobre os defeitos (localização, classificação e severidade). As condições de superfície dos pavimentos asfálticos são avaliadas pelas seguintes normas: a) DNIT 005/2003 - TER; b) DNIT 006/2003 - PRO; c) DNIT 007/2003 - PRO; d) DNIT 008/2003 - PRO; e) DNIT 009/2003 - PRO.

A Figura 2.7 apresenta planilhas de uso corrente, para se anotarem informações referentes ao levantamento dos defeitos superficiais.

PLANILHA LEVANTAMENTO DE DEFEITOS NO CAMPO				
IDENTIFICAÇÃO DA SEÇÃO: _____				
DATA DO LEVANTAMENTO (DIA/MÊS/ANO): ____/____/____				
TÉCNICOS: _____				
TIPO DE DEFEITO		NÍVEL DE SEVERIDADE		
		BAIXA	MÉDIA	ALTA
1	TRINCAS POR FADIGA (m ²)			
2	TRINCAS EM BLOCOS (m ²)			
3	TRINCAS NOS BORDOS (m)			
4	TRINCAS LONGITUDINAIS (m)			
	4a - Nas trilhas de roda (m)			
	4a - Selagem (m)			
	4b - Fora das trilhas de roda (m)			
	4b - Selagem (m)			
5	TRINCAS POR REFLEXÃO			
	Número			
	5a - Trincas transversais (m)			
	5a - Selagem (m)			
	5b - Trincas longitudinais (m)			
	5b - Selagem (m)			
6	TRINCAS TRANSVERSAIS (m)			
	Número			
	Extensão (m)			
	Selagem (m)			
7	REMENDOS			
	Número			
	Área (m ²)			
8	PANELAS			
	Número			
	Área (m ²)			
9	DEFORMAÇÃO PERMANENTE NAS TRILHAS DE RODA (*)			
	(% da extensão da sessão)			
10	CORRUÇÃO			
	Número			
	Área (m ²)			
11	EXSUDAÇÃO (m ²)			
12	AGREGADOS POLIDOS (m ²)			
13	DESGASTE (m ²)			
14	DESNÍVEL ENTRE PISTA E ACOSTAMENTO (**)			

TIPO DE DEFEITO		NÍVEL DE SEVERIDADE		
		BAIXA	MÉDIA	ALTA
15	BOMBEAMENTO			
	Número			
	Extensão (m)			
16	OUTRO (descrever): _____			
OBSERVAÇÃO: REGISTRAR "0" PARA OS TIPOS DE DETERIORIZAÇÃO E/OU NÍVEIS DE SEVERIDADE NÃO ENCONTRADOS				
9 (*) DEFORMAÇÃO PERMANENTE NAS TRILHAS DE RODA				
TRILHA INTERNA			TRILHA EXTERNA	
Nº	Distância (m)	Deformação (mm)	Nº	Deformação (mm)
1	0		1	0
2	15		2	15
3	30		3	30
4	45		4	45
5	60		5	60
6	75		6	75
7	90		7	90
8	105		8	105
9	120		9	120
10	135		10	135
11	150		11	150
14(**) DESNÍVEL ENTRE PISTA E ACOSTAMENTO				
Leitura	Distância (m)	Desnível (mm)		
1	0			
2	15			
3	30			
4	45			
5	60			
6	75			
7	90			
8	105			
9	120			
10	135			
11	150			

Figura 2.7 - Planilhas utilizadas no levantamento de defeitos superficiais
Fonte: Fernandes et al. (1999)

Na Figura 2.8, lado esquerdo, apresenta-se um exemplo de um

⁵ *Trecho* (ou segmento) *homogêneo* é um trecho da rodovia considerado homogêneo de acordo com algum(uns) parâmetro(s). Por exemplo: homogêneo em relação ao tráfego, em relação às condições de superfície, em relação à estrutura do pavimento, etc.

mapeamento de defeitos superficiais e, do lado direito, os símbolos utilizados para a representação dos defeitos.




Figura 2.8 - Exemplo de mapeamento dos defeitos (lado esquerdo) e respectivos símbolos utilizados (lado direito)
Fonte: Fernandes et al (1999)

Com o técnico dentro do veículo ou percorrendo o trecho a pé, trata-se de uma operação com características essencialmente manual, perigosa, lenta, cansativa, de custo elevado e com interferência no trânsito. Devido a algumas das características citadas (levantamento manual, perigoso, cansativo), há de se questionar a consistência dos resultados do trabalho de campo.

Esse questionamento também ocorreu em muitos países com extensa malha rodoviária. Para tentar amenizar esses problemas, países como os Estados Unidos, o Canadá, o Japão, a Austrália, a França e outros, vêm desenvolvendo pesquisas no sentido de substituir esses procedimentos manuais por procedimentos automáticos, com o mínimo de intervenção humana e com o máximo de segurança, tanto para o técnico como para os usuários da via.

A solução vem sendo apresentada em forma de um *veículo avaliador*

constando de um furgão com vários sensores adaptados à sua estrutura, cada um com uma função específica - Figura 2.9. No caso dos defeitos superficiais, a aquisição dos dados é feita através de fotografias ou filmagem da superfície do pavimento. Posteriormente, essas imagens são processadas com a intenção de identificar os defeitos.




Figura 2.9 - Veículo avaliador, Sistema *Hawkeye*
Fonte: ARRB (2008)

Esses países citados (Estados Unidos, o Canadá, o Japão, a Austrália, a França, etc) investem milhões de dólares em pesquisas nessa área. Aqueles que detêm a tecnologia, ou a mantêm como segredo absoluto, ou a vende a preço realmente alto para eventuais consumidores, na forma de uma “caixa-preta” - explica-se como usar, mas não explica como está sendo feito.

Assim, o desenvolvimento de uma tecnologia genuinamente brasileira, com características regionais, e que venha ao encontro das tendências mundiais, passa a ser um valioso instrumento da engenharia de avaliação rodoviária.

Esse é um dos objetivos da presente tese: o desenvolvimento de um sistema para identificar automaticamente defeitos superficiais do pavimento asfáltico, através de imagens digitais. Propõe-se fazer uma análise automática das trincas, panelas e remendos. Defeitos cuja análise tem uma natureza mais complexa, tais como, as corrugações, depressões, desníveis, trilhas de roda e

escorregamento de massa não serão analisados.

2.3. LEVANTAMENTO DOS DEFEITOS COM O USO DE IMAGENS

Nesta seção, aborda-se o levantamento dos defeitos superficiais dos pavimentos asfálticos com o uso de imagens, como uma alternativa promissora e vantajosa ao método manual de levantamento dos defeitos.

As imagens de um pavimento podem ser obtidas em nível orbital, sub-orbital ou terrestre, cujas explicações vêm a seguir.

2.3.1. IMAGENS EM NÍVEL ORBITAL

Imagens em nível orbital são obtidas por sensores localizados a algumas centenas de quilômetros da superfície terrestre, carregados em plataformas (satélites) em órbitas ao redor da Terra.

Com a disponibilização das imagens de sensores de altíssima resolução, como as imagens dos programas IKONOS II e *Quickbird 2*, iniciou-se no mundo científico, uma série de pesquisas, utilizando essas imagens em várias áreas do conhecimento, tais como, agricultura, mapeamento, planejamento urbano, meio ambiente, etc. A grande motivação era referente à resolução espacial⁶ das imagens que aumentara consideravelmente em relação aos outros sensores orbitais até então utilizados.

A Tabela 2.3 apresenta algumas informações sobre os sensores dos programas IKONOS II e *QuickBird 2*. Ambos os sensores captam em 5 bandas, porém o *QuickBird 2* tem uma resolução espacial melhor que o IKONOS II, tanto na banda pancromática quanto nas bandas multiespectrais⁷. O conceito de Quanto ao imageamento (obtenção das cenas), ela é menor no IKONOS II. Já analisando a revisita, ou seja, a obtenção da mesma cena consecutivamente, ambos dependem da latitude do local. No caso do IKONOS II, a revisita depende

⁶ *Resolução espacial* de uma imagem está relacionada à capacidade de se discriminar na imagem objetos de seus vizinhos, sendo tanto melhor quanto maior for a resolução espacial;

⁷ O conceito de *pancromático* e *multiespectral* é discutido no Capítulo 3, seção 3.1.

também do tipo de imagem, se pancromática ou multiespectral.

Ainda é relativamente restrita a utilização das imagens desses sensores com aplicação na engenharia rodoviária. A comunidade científica pouco tem produzido a esse respeito e a abordagem quase sempre recai em levantamentos de faixas de terreno (corredores) e modelo digital de elevação para estudo de traçados, planejamentos e estudos ambientais.

Tabela 2.3 - Algumas características dos sensores IKONOS II e QuickBird 2
Fonte: Moreira (2005)

Programa IKONOS II		Programa QuickBird 2	
Ano lançamento	1999	Ano lançamento	2001
Altitude	680 km	Altitude	450 km
Bandas	4 - multiespectral 1 - pancromática	Bandas	4 - multiespectral 1 - pancromática
Resolução espacial	4m - multiespectral 1m - pan	Resolução espacial	2,4m - multiespectral 0,6m - pancromática
Resolução radiométrica ⁸	11 bits (2.048 níveis de cinza)	Resolução radiométrica	11 bits (2.048 níveis de cinza)
Imageamento	cenos 13 x 13 km	Imageamento	cenos 16,5 x 16,5 km
Revisita ⁹ <i>off</i> nadir	2,9 dias - pancromática 1,5 dias - multiespectral	Revisita <i>off</i> nadir	de 1 a 3,5 dias - conforme latitude

Tratando-se de levantamentos de defeitos com o uso das imagens de altíssima resolução, a produção científica é pequena, possivelmente devido a alguns fatores: a) as imagens são de custo alto e, via de regra, são necessárias várias imagens para cobrir uma rodovia extensa; b) o aparecimento de nuvens prejudica a análise das imagens; c) de uma maneira geral, a obtenção das imagens é um pouco demorada, dificultando avaliações que necessitam ser feitas mais rapidamente; d) a resolução espacial da imagem, embora seja considerada alta, ainda não é o suficiente para essa aplicação específica. Por exemplo, como identificar uma trinca de 3 mm de espessura em uma imagem cuja resolução espacial é de 1 m?

⁸ Resolução radiométrica de um sensor está associada à sua capacidade em discriminar sinais elétricos com pequenas diferenças de intensidade (MOREIRA, 2005);

⁹ Valores de revisita para latitudes entre $\pm 40^\circ$, sendo menor para latitudes maiores.

2.3.2. IMAGENS EM NÍVEL SUB-ORBITAL

Imagens em nível sub-orbital (também denominadas *imagens aéreas*) são obtidas por sensores transportados por uma aeronave, voando até cerca de 4.500 m de altitude. É a área de atuação da Fotogrametria.

Recentemente, o uso de sensores sub-orbitais hiperespectrais e sensores com tecnologia laser, adicionados às câmeras métricas digitais parece estar colaborando para uma nova fase nessa área.

No Capítulo 3, seção 3.2, faz-se citações sobre trabalhos que utilizaram sensores hiperespectrais (MOREIRA *et al.*, 2007; HEROLD *et al.*, 2003; HEROLD *et al.*, 2004; HEROLD *et al.*, 2004a).

2.3.3. IMAGENS EM NÍVEL TERRESTRE

Imagens em nível terrestre são obtidas por sensores transportados por um veículo ou pessoa. Neste caso, o sensor fica muito próximo do alvo, ou seja, a poucos metros dele.

O uso de imagens terrestres na identificação de defeitos superficiais no pavimento tem sido largamente explorado desde algum tempo. Registros trazem informações que as pesquisas iniciaram na década de 1960, e seus métodos foram desenvolvidos a fim de se tentar estabelecer uma forma de levantamento que seja confiável, preciso, universal, de baixo custo, rápido e com boa repetitividade (BARELLA, 2001).

A Figura 2.10 apresenta a evolução do processo usando imagem para identificar defeitos ao longo do tempo. Na fase inicial, nas décadas de 1960 e 1970, as fotografias eram analógicas e armazenadas em um rolo de filmes com algumas centenas de metros, reveladas e editadas em laboratório fotográfico. Os procedimentos de identificação dos defeitos eram visuais e, posteriormente, com auxílio de *software* específico, mas que não eliminava a característica manual da operação. Na fase seguinte, na década de 1980, passou-se a fazer filmagens do pavimento com câmeras de vídeo analógicas e a identificação dos

defeitos era efetuada no escritório, através da visualização da fita quadro a quadro. Na fase de digitalização das imagens (fotografias e vídeo), entre as décadas de 1980 e 1990, usaram *scanners* e placas digitalizadoras para obterem-se imagens digitais a partir de imagens analógicas; os defeitos passaram a ser identificados por procedimentos automáticos, através de computadores. Para finalizar, a última e atual etapa, a partir da década de 1990, é definida pela aquisição de imagens digitais e sofisticados procedimentos de identificação de defeitos.





Figura 2.10 - Desenvolvimento histórico da aquisição de imagens para uso na identificação de defeitos
Fonte: adaptado de Barella (2001)

Muitos trabalhos têm sido desenvolvidos nessa área e a literatura é relativamente vasta. Citam-se alguns trabalhos que utilizaram imagens terrestres com o objetivo de determinar defeitos superficiais nos pavimentos.

Barella (2001), visando diminuir as dificuldades e problemas relacionados aos levantamentos *in loco* de defeitos superficiais de pavimentos, desenvolveu um sistema para capturar imagens do pavimento a partir de um veículo em movimento. Posteriormente, no escritório, essas imagens eram interpretadas visualmente, obtendo-se o levantamento dos defeitos do pavimento. Segundo Barella (2001), o sistema desenvolvido apresentou-se promissor para as atividades de inventário de defeitos no pavimento. Na Figura 2.11 (a) apresenta-se o sistema desenvolvido por Barella (2001), constando de um veículo com uma estrutura fixada ao mesmo, para sustentar a câmera e, na extremidade, a câmera. Dentro do veículo encontra-se um computador para receber os dados da câmera via cabeamento. Na Figura 2.11 (b) tem-se uma imagem adquirida pelo sistema, onde se visualiza remendos sobre o pavimento.



(a)



(b)

Figura 2.11 - Sistema desenvolvido por Barella (2001)
(a) Vista do veículo, plataforma e câmera; (b) imagem adquirida pelo sistema
Fonte: Barella (2001)

O *National Cooperative Highway Research Program* (NCHRP, 2004) apresentou uma síntese de informações coletadas em 2003 nos departamentos de transporte americano (DOTs), nos *Federal Highway Administration* (FHWA), nas províncias do Canadá e no *World Road Association*, denominado *A Synthesis of Highway Practice* e que apontou esforços no desenvolvimento, pesquisa e prática da comunidade rodoviária voltados para o procedimento da automatização dos dados, obtenção e processamento, sobre as condições dos pavimentos. O NCHRP analisou custos e benefícios das técnicas de automatização, frequências de monitoramento, protocolos utilizados e o contraste entre o estado da arte e estado da prática no procedimento da automatização nos órgãos que participaram da síntese. Verificou-se que todos os DOTs fazem uso de algum mecanismo de medida automática de defeitos (de superfície, irregularidade, etc). Trinta agências utilizam imagem do pavimento e quatorze agências fazem uso de procedimentos automáticos para a detecção de defeitos com o uso de imagens (NCHRP, 2004).

Em termos de sistemas comerciais para obtenção de imagens e detecção automática de defeitos superficiais, cita-se entre outros: a) *Hawkeye 2000 series* - trata-se de um sistema de avaliação modular cujas características podem ser implementadas à medida das necessidades do cliente, possui um pacote projetado para identificação e localização de áreas de defeitos superficiais, opera na velocidade operacional da via e utiliza câmeras digitais de alta resolução - Figura 2.9 (ARRB, 2008); b) Sistema ARAN - trata-se de um sistema que pode ser implementado em vários tipos de chassis de veículos, sendo também modular (nos moldes do sistema *Hawkeye 2000 series*) e o sistema que a empresa produz para a detecção de defeitos no pavimento é denominado *Wisecrux* - Figura 2.12 (FUGRO, 2008).




Figura 2.12 - Sistema ARAN, da Fugro Roadware
Fonte: Fugro (2008)

O mercado brasileiro de avaliação rodoviária vem crescendo anualmente, motivando várias empresas a disputarem esse mercado. No entanto, não se tem notícias de uso, no Brasil, de qualquer sistema de detecção automático de defeitos superficiais.

2.4. RESUMO DO CAPÍTULO

Como síntese desse capítulo, fez-se uma abordagem sobre defeitos superficiais em pavimentos asfálticos. Citaram-se os procedimentos manuais e com o uso de imagens como meio para a identificação de defeitos superficiais no pavimento.

Quanto ao uso e aplicabilidade de imagens orbitais de altíssima resolução na detecção de defeitos superficiais, vai depender de melhores resoluções espaciais dessas imagens, o que provavelmente deve ocorrer nos próximos anos.

Já o uso de imagens sub-orbitais digitais (hiperespectrais, tecnologia *laser scan* e fotogramétrica) na detecção de defeitos superficiais, parece ser uma possibilidade promissora, mas é certo que ainda falta muita pesquisa nessa área.

As imagens terrestres, obtidas por câmeras fixadas nos veículos, juntamente com um sistema de detecção de defeitos superficiais, capazes de extrair das imagens do pavimento informações relevantes para um sistema de gerência, parece ser o caminho mais promissor nessa área.

CAPÍTULO 3

CURVAS ESPECTRAIS DE PADRÕES DO PAVIMENTO ASFÁLTICO

O objetivo desse capítulo é obter, com o uso de um espectrorradiômetro, as curvas espectrais de padrões das superfícies dos pavimentos asfálticos em variadas condições de conservação.

Uma aplicação prática abordada com as curvas espectrais obtidas é a pesquisa de faixas espectrais que melhor caracterizem os diferentes padrões do revestimento asfáltico (RA). Assim, pretende-se utilizar essa informação para especificar um sistema sensor, direcionando o investimento especificamente para essa aplicação.

3.1. INTRODUÇÃO

O Sol envia sua radiação para a Terra, que interage com os alvos na superfície terrestre, gerando frações de reflexão, transmissão e absorção.

Sistemas sensores, também chamados de radiômetros, são equipamentos construídos para detectar e registrar uma ou mais frações da radiação eletromagnética em determinada faixa do espectro eletromagnético, gerando informações que possam ser transformadas em um produto, seja uma imagem, um gráfico ou uma tabela.

A obtenção do produto com o uso de um radiômetro pode ser assim explicada - Figura 3.1: a radiação chega a um coletor que a envia para o detector e, em seguida, no processador, o sinal é manipulado, obtendo-se o resultado desejado - tabela, curva, produto (MOREIRA, 2005).

Maiores detalhes sobre a função de cada parte do radiômetro é explicado na subseção 3.1.2.




Figura 3.1 - Partes componentes de um sistema sensor e possíveis resultados
Fonte: adaptado de Moreira (2005)

Um sistema sensor pode ter vários tipos de classificação, sendo que todas elas são baseadas na fonte de radiação e no produto gerado (MOREIRA, 2005).

São exemplos de classificações de sistemas sensores, utilizados na literatura: a) quanto à fonte de radiação (ativo e passivo ou imageador e não-imageador); b) quanto ao princípio de funcionamento (de varredura – *scanning* e de não-varredura); c) quanto ao tipo de produto (gráficos, tabelas, imagens); etc.

Os sistemas sensores não-imageadores medem a radiação de uma forma pontual. Já os sistemas sensores imageadores são equipamentos cujo resultado apresenta-se em forma de imagem de uma área (cena).

Na Figura 3.2 apresenta-se um sistema sensor de varredura. Trata-se de uma câmera de varredura linear, onde uma imagem é construída de acordo com o deslocamento do veículo; as consecutivas linhas vão sendo capturadas até formarem uma imagem.

A imagem digital gerada por um sensor remoto¹ é formada por uma

¹ Um sensor remoto é um equipamento que não tem contato direto com o objeto, área ou fenômeno sob investigação; é um sistema óptico-eletrônico capaz de detectar e registrar o fluxo de radiação eletromagnética refletido ou emitido pelos objetos.

matriz de pontos denominados *pixel*², e cada um deles representam, através de seu nível digital (valor numérico), a quantidade de radiação refletida ou emitida de parte da cena que representa.




Figura 3.2 - Esquema de utilização de uma câmera terrestre de varredura linear
Fonte: adaptado de Barella (2001)

A Figura 3.3 (a) apresenta uma imagem analógica formada por um quadrado preto central e um retângulo branco no seu entorno. Na Figura 3.3 (b), tem-se a correspondente representação digital para uma imagem de 8 bits (valores numéricos de 0 a 255), onde os valores “0” representam o quadrado preto e os valores “255” representam a área branca.




Figura 3.3 - Imagem analógica (a) e sua correspondente imagem digital em 8 bits (b)

A identificação dos defeitos superficiais nos pavimentos, através do uso de imagens, pode ser feito através da forma, tamanho, cor, tonalidade, textura,

² *Pixel* é o menor ponto que forma uma imagem digital, sendo que milhares de *pixels* formam a imagem inteira.

etc. No entanto, dependendo da resolução espacial da imagem, esses mecanismos de identificação tornam-se razoavelmente complexos, pois, em baixa resolução espacial, muitos objetos são integrados em um mesmo *pixel*, resultando em níveis digitais cujos valores representam o valor médio da reflectância³ desses objetos.

No sensoriamento remoto, o conhecimento das características espectrais de objetos da superfície terrestre tem sido utilizado como uma importante ferramenta na sua identificação. Assim, a interpretação de cada objeto presente na imagem depende de um adequado conhecimento de seu comportamento espectral. A medição radiométrica dos objetos terrestres tem sido utilizada com o objetivo de compreender melhor as relações entre as propriedades dos objetos e seu comportamento espectral (STEFFEN *et al.*, 1996).

Particularmente, no caso do revestimento asfáltico, seu envelhecimento natural é causado pela sua reação com o oxigênio do ar, reações fotoquímicas com a radiação solar e a influência do calor. Esses agentes, agindo na mistura asfáltica, resultam na perda de componentes oleosos do asfalto pela volatilização, mudanças da composição do asfalto devido a oxidação e aumento de viscosidade do asfalto, acarretando o seu endurecimento. Com a idade do revestimento e sua deterioração há um aumento na reflectância da superfície asfáltica (HEROLD *et al.*, 2004a).

Baseado nessa constatação, esse capítulo foi desenvolvido com o objetivo de explorar as características espectrais de imagens multiespectrais do pavimento asfáltico, sendo essas características utilizadas como variáveis discriminatórias em um sistema automático de reconhecimento de padrão (Capítulo 4).

Nesse momento, é adequado fazer a devida distinção de nomenclaturas utilizadas em imagens e que costumam causar certa confusão, relacionados à

³ *Reflectância* é um índice que mede a capacidade de um objeto de refletir a energia radiante (MOREIRA, 2005).

distinção entre imagens monocromática e coloridos, cujas explicações apóiam-se na Figura 3.4.




Figura 3.4 – Nomenclatura dos diferentes tipos de imagens

A imagem pancromática (o correto é *imagem do sensor pancromático*) é uma imagem monocromática ($Q > 1$) da cena, obtida por um sensor capaz de registrar a energia eletromagnética através de diversas regiões do espectro eletromagnético, normalmente de 400 a 700 nm. É uma imagem em tons de cinza e, na maioria dos sensores remotos orbitais, tem resolução espacial quatro vezes maiores que a resolução espacial da imagem multiespectral correspondente.

A imagem multiespectral (o correto é *imagem do sensor multiespectral*) é uma imagem monocromática ($Q > 1$) da mesma cena formada por bandas espectrais contínuas, relativamente largas, podendo chegar a dezenas de bandas espectrais, sendo o tipo de imagem mais utilizada em sensoriamento remoto orbital. Por exemplo, o sensor ETM⁺ do Landsat-7 opera em oito bandas espectrais e o sensor MODIS opera em 36 bandas espectrais.

A imagem hiperespectral (o correto é *imagem do sensor hiperespectral*) é uma imagem formada por bandas espectrais contínuas e muito estreitas, podendo chegar a ter centenas de pequenas bandas espectrais. De acordo com Latorre (1998), esse tipo de imagem tem sua aplicação na produção dos tradicionais mapeamentos da cobertura da superfície, bem como em novos

mapeamentos baseados nas medidas quantitativas das propriedades da superfície terrestre.

A imagem colorida é formada pela combinação de bandas obtidas pelos sensores multiespectrais ou hiperespectrais. Por exemplo, a composição colorida RGB é formada pelas bandas 1 (blue), 2 (green) e 3 (red) do sensor ETM⁺ do Landsat-7.

Na Figura 3.5 (a) tem-se uma imagem hiperespectral, obtida pelo sensor AVIRIS. A Figura 3.5 (b) é uma imagem monocromática da superfície do RA e a Figura 3.5 (c) é uma imagem binária, da mesma área da imagem monocromática.




Figura 3.5 - Diferentes tipos de imagens:
(a) - imagem hiperespectral (Fonte: Herold *et al.*, 2003);
(b) - imagem monocromática; (c) - imagem binária

3.1.1. UMA ABORDAGEM SOBRE A REFLECTÂNCIA

Quando a radiação eletromagnética interage com um objeto, pode ser refletida, absorvida ou mesmo transmitida. Em geral, a parte absorvida é transformada em calor e a parte refletida retorna a atmosfera. Ressalta-se o fato de que qualquer objeto com temperatura superior ao zero grau absoluto (-273°C) emite um espectro contínuo de radiação eletromagnética, que depende da temperatura do objeto.

De acordo como a Figura 3.6, a radiação eletromagnética incidente sobre um objeto (ϕ_i) é a soma da radiação refletida (ϕ_r) com a radiação absorvida (ϕ_a) e a radiação transmitida (ϕ_t) - Equação 3.1.




Figura 3.6 - Interação entre radiação incidente e objeto
Fonte: adaptado de Landgrebe (2003)

$$\phi_i = \phi_r + \phi_a + \phi_t \quad (3.1)$$

Normalizando a Equação 3.1 em relação o fluxo incidente, obtém-se a Equação 3.2, sendo que a soma da reflectância (ρ) com a absorptância (α) e a transmitância (τ), igual a um. Essas três grandezas são consideradas propriedades radiométricas do alvo analisado e expressas, normalmente, em porcentagem.

$$1 = \rho + \alpha + \tau \quad (3.2)$$

Segundo Moreira (2005), *absortância* é o índice que mede a capacidade de um objeto em absorver a energia radiante. Já a *transmitância* é o índice que mede a capacidade de um objeto em transmitir energia radiante. Por exemplo, um objeto escuro e opaco tem um valor baixo para a reflectância, alto para a absorptância e nulo para a transmitância.

O fluxo absorvido não pode ser medido diretamente, assim, a absorptância pode ser determinada a partir dos valores da transmitância e da reflectância.

A interação da radiação eletromagnética (REM) com um material varia com o comprimento de onda. Moreira *et al.* (2007), relata que esse fenômeno tem sua explicação na intensidade da iluminação solar e, principalmente, nas propriedades físicas, químicas e biológicas dos objetos.

A *radiometria* é o conjunto das técnicas utilizadas para a avaliação de quantidades de energia radiante. Os equipamentos que medem essa energia são genericamente chamados de *radiômetros* e, no mercado, existem radiômetros que permitem quantificar diferentes bandas da radiação eletromagnética.

De acordo com Steffen *et al.* (1996), as principais grandezas radiométricas são, no Sistema Internacional - SI: *energia radiante* (Q) - é a energia transportada pela radiação eletromagnética, expressa em *joule* (J); *fluxo radiante* (ϕ) - é a quantidade de energia que passa por uma unidade de área em cada segundo, expresso em $W.m^{-2}.s^{-1}$; *densidade de fluxo radiante* ($d\phi/dA$) - é o fluxo radiante de uma superfície por unidade de área, cuja unidade é $W.m^{-2}$; *irradiância* (E) - é o fluxo radiante incidente por unidade de área, numa dada direção, com relação à normal, expresso em $W.m^{-2}$; *exitância* (M) - é o fluxo radiante ascendente por unidade de área, numa dada direção, com relação à normal, expresso em $W.m^{-2}$; *intensidade radiante* (I) - é o fluxo radiante que provém de uma fonte por unidade de ângulo sólido⁴ na direção considerada, expressa em $W.sr^{-1}$; *radiância* (L) - descreve a distribuição da radiação no espaço de uma superfície refletora ou emissora e definida, para uma determinada direção, como sendo o fluxo radiante (emitido ou refletido) por unidade de ângulo sólido na direção considerada e por unidade de área projetada, expressa em $W.m^{-2}.sr^{-1}$; *reflectância* (ρ) - definida como a razão entre o fluxo refletido e o fluxo incidente em uma superfície de interesse, sendo adimensional (leva-se em conta o posicionamento do alvo, do sensor e da fonte de iluminação); *fator de reflectância* (FR) - é a razão entre o fluxo refletido em uma superfície e o fluxo refletido, na mesma geometria, por uma superfície padrão perfeitamente difusora, expressa em porcentagem.

As fontes de radiação eletromagnética irradiam com diferentes intensidades dentro do espectro eletromagnético⁵. Assim, as grandezas citadas

⁴ Representa o ângulo cônico definido a partir do centro de uma esfera e expresso pela razão entre a área da calota esférica e o quadrado do raio da esfera;

⁵ *Espectro eletromagnético* é o conjunto de diferentes tipos de radiação eletromagnética conhecidas, variando da radiação gama, com comprimento de onda abaixo de 1 Angstrom, até as ondas de rádio, com comprimento de onda acima de 1m.

no parágrafo anterior podem ser consideradas em pequenos intervalos de comprimento de onda, constituindo-se as chamadas *grandezas radiométricas espectrais* (RIBEIRO, 1992). Esses pequenos intervalos de comprimento de onda somente são possíveis de se obter devido à instalação de redes de difração nos radiômetros (aqui denominados *espectrorradiômetros*), que são dispositivos ópticos capazes de selecionarem as bandas espectrais (RIBEIRO, 1992).

O registro gráfico da reflectância obtido pelo espectrorradiômetro ao longo de uma faixa do espectro eletromagnético fornece uma curva que descreve as propriedades radiométricas de um determinado material. Segundo Mather (2004), esta curva típica de cada material pode ser denominada *curva espectral* ou *curva de reflectância* e constitui uma característica para identificação dos alvos de estudo em imagens multiespectrais.

A Figura 3.7 apresenta uma curva de reflectância de um alvo, onde o eixo horizontal representa o comprimento de onda (em nanômetros - *nm*) e o eixo vertical representa a reflectância (em %). Essa curva representa o resultado da interação da energia radiante com o material, nos mais variados comprimentos de onda, sendo que as variações dos valores na reflectância são indicadoras de propriedades intrínsecas do material.




Figura 3.7 - Curva de reflectância de vários revestimentos
Fonte: modificado de Herold *et al.* (2004)

3.1.2. ESQUEMA DE UM RADIÔMETRO

Segundo Steffen *et al.*(1996), os seguintes componentes são destacados em um radiômetro: a) *coletor* - componente óptico formado por lentes e espelhos e cuja função é concentrar o fluxo de radiação proveniente da amostra sobre o detector; b) *detector* - é um dispositivo feito de materiais cujas propriedades elétricas variam ao absorver um fluxo de energia radiante; c) *processador* - é um sistema capaz de amplificar o fraco sinal elétrico gerado pelo detector, diminuindo os indesejáveis “ruídos”, consequentemente sua influência nas medidas, podendo também fazer a conversão dos sinais elétricos analógicos em digitais; d) *redes de difração* - têm a finalidade de selecionar a banda espectral do fluxo radiante que atinge o detector; e) *unidades de saída* - são dispositivos utilizados para registrar a amplitude dos sinais vindos do processador.

Na Figura 3.8 (a) tem-se um esquema de um radiômetro, no qual se observam os componentes citados no parágrafo anterior. Na Figura 3.8 (b), destaca-se a montagem do radiômetro no campo, com o coletor fixado a uma estrutura de sustentação, cuja altura é função do alvo e do campo de visada do radiômetro (Ω).




Figura 3.8 - Esquema de um radiômetro (a) e montagem no campo (b)
Fonte: modificado de Steffen *et al.* (1996)

Na seção 3.2 faz-se uma abordagem sobre trabalhos que utilizaram

medidas de reflectância e algumas conclusões importantes a esse respeito.

3.2. REVISÃO DA LITERATURA

Milton (1987) aponta a necessidade de medir a reflectância espectral das superfícies naturais ou artificiais, baseada, no mínimo, em três motivos: a) o dado espectral *in loco* é fundamental para avaliação dos sistemas de sensoriamento remoto existentes, através da sincronia das medidas feitas em campo com as medidas feitas pelo sensor; b) a necessidade de ampliar o entendimento da relação entre a reflectância espectral e os mais variados tipos de superfícies; c) o motivo para a coleta de dados espectrais *in loco* é que ele permite avaliar o potencial das diferentes bandas espectrais do sensor remoto para um alvo específico.

Jensen (1983) relata que a resposta espectral não é constante para um determinado alvo, sendo dependente de suas propriedades físicas, químicas e biológicas, do ângulo de visada do sensor e dos efeitos atmosféricos. Jensen (1983) pesquisou em laboratório a resposta espectral de alguns alvos urbanos, utilizando um espectrorradiômetro para fazer as medidas e construiu curvas de reflectância para os principais alvos urbanos (grama, RA, concreto, telha, ardósia, turfa, tijolo).

Sousa e Kux (2005) desenvolveram uma pesquisa sobre comportamento espectral de alvos urbanos e afirmam que o conhecimento das características espectrais dos alvos urbanos é uma importante informação na classificação da cobertura da terra através de imagens. Sousa e Kux (2005) afirmam ainda que o conhecimento espectral dos componentes do *pixel* pode ser útil para a aplicação de modelos de mistura, porque muitos objetos do terreno são integrados em um mesmo *pixel*.

Moreira *et al.* (2007) desenvolveram um trabalho com dados do sensor multiespectral aerotransportado HSS (*Hyperspectral Scanner System*), com imagens de São José dos Campos (alvos urbanos), na resolução de 2,7m. Esse sensor dispõe de 50 canais, distribuídos entre as regiões do visível até o

infravermelho termal. A finalidade da pesquisa foi comparar os valores espectrais dos *pixels* da imagem reflectância obtida pelo HSS às curvas de reflectância obtidas com um espectrorradiômetro, em campo e em laboratório. Vários alvos foram analisados, citando-se: áreas edificadas, pátio de concreto, vegetação, solo exposto, corpos d'água, pavimento asfáltico, telhados em fibrocimento, telhados metálicos, telhados cerâmicos e toldos de lonas plásticas. Moreira *et al.* (2007) concluíram que o sensor HSS foi capaz de reproduzir adequadamente as principais feições espectrais de vegetação, solos, corpos d'água, superfícies metálicas e materiais em PVC.

Tradicionalmente, as diversas aplicações do sensoriamento remoto hiperespectral têm abordado a possibilidade de identificação de minerais em rochas e solos, sedimentos em suspensão ou algas em corpos d'água, e de variáveis biofísicas da vegetação (LIANG, 2004). Tratando-se, agora, de pavimentos asfálticos pouco se tem pesquisado nessa área.

Uma pesquisa para identificar as propriedades refletivas da superfície do RA foi realizada por Staenz e Itten (1982). Foram analisados o estado da superfície, a estrutura e diferentes tempos de uso, num período de cinco meses. O resultado mostrou um baixo intervalo de variação do fator de reflectância, de 5% a 11% na região do visível e de 6% a 13% na região do infravermelho próximo.

Destacam-se os trabalhos do grupo de pesquisadores formado por Chris Funk, Dar A. Roberts, Margaret E. Gardner, Martin Herold e Val Noronha, do Departamento de Geografia da Universidade da Califórnia, Santa Bárbara, USA. A maioria de suas publicações, em nível sub-orbital, são baseadas em análises de imagens hiperespectrais de alta resolução espacial (4m), obtidas através do projeto *Airborne Visible/Infrared Imaging Spectrometer* (AVIRIS). O AVIRIS é um sensor sub-orbital que capta a radiação do espectro eletromagnético em 224 bandas no comprimento de ondas entre 350 e 2400 nm (LATORRE, 1998). Citam-se, a seguir, alguns trabalhos do grupo de pesquisadores.

Herold *et al.* (2003) concluíram que é possível descrever, em linhas gerais, a idade do pavimento e alguns defeitos específicos como, por exemplo, o desprendimento de agregado. No entanto, outros tipos de defeitos, tais como, trincas e trilhas de roda não são detectados na resolução espacial de 4m.

Herold *et al.* (2004) mostraram que nos pavimentos asfálticos a reflectância vai aumentando com o passar dos anos (idade do pavimento e deterioração).

Herold *et al.* (2004a) analisaram a possibilidade de se fazer o mapeamento de pavimentos asfálticos com o uso de imagens hiperespectrais e estudaram a combinação da espectrometria de campo com métodos de levantamento de campo e sensoriamento remoto hiperespectral para explorar o potencial do sensoriamento remoto no mapeamento de defeitos em pavimentos asfálticos em áreas urbanas. Herold *et al.* (2004a) concluíram que a idade e a degradação da superfície do pavimento são representadas por características espectrais distintas.

3.3. MATERIAIS E MÉTODOS

Nessa seção, discorre-se sobre dois experimentos desenvolvidos com o objetivo de explorar as informações espectrais do alvo revestimento asfáltico - RA.

3.3.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

Optou-se, nesse experimento, em escolher algumas vias internas e áreas de estacionamento do Instituto Nacional de Pesquisas Espaciais (INPE), situado na cidade de São José dos Campos, estado de São Paulo. A escolha do local deveu-se, em primeiro lugar, à utilização do equipamento cedido pelo INPE e, em segundo lugar, ao fato daquelas áreas possuírem vários tipos de defeitos, o que possibilitou distinguir uma variedade de padrões para a análise com o uso do espectrorradiômetro. As vias do INPE são utilizadas basicamente por trânsito leve, mas como a maioria de nossas vias de trânsito, caracteriza-se pela pouca ou quase nenhuma manutenção, apresentando vários tipos de

defeitos, sendo os mais comuns as trincas e as panelas.

A Figura 3.9, apresenta uma vista panorâmica das instalações do INPE e do seu sistema viário, sendo apontados (elipse amarela) os locais onde se fez as medições com o espectrorradiômetro, em um total de 11 observações. As medições ocorreram no período da manhã (entre 10h e 12h) e no período da tarde (entre 14h e 15h30min) do dia 23 de abril de 2008. As condições do tempo foram as ideais, com o sol completamente a descoberto.



Figura 3.9 - Vista aérea das instalações e vias do INPE
Fonte: imagem obtida no Google Earth (23/04/2008)

3.3.2. MATERIAL

Foi utilizado um espectrorradiômetro da marca *Analytical Spectral Device Inc*, modelo *FieldSpec*, com FOV (*Field of View*) de 25°, que opera na região do visível, do infravermelho próximo e parte do infravermelho médio (de 350 nm a 2.500 nm), composto de: uma unidade controladora, cabos de conexão, placa de referência, unidade detectora (pistola de mão), *notebook* e bateria. Esse equipamento foi gentilmente cedido pelo INPE para o desenvolvimento do experimento. A Figura 3.10 é uma foto obtida no dia do experimento. Destacam-se, em forma de texto, alguns itens do equipamento.



Figura 3.10 - Espectrorradiômetro *FieldSpec* utilizado no experimento

3.3.3. OBTENÇÃO DOS DADOS DE CAMPO

A medida que caracteriza o comportamento espectral de objetos sob a superfície terrestre deve, preferencialmente, ser realizada em condições de campo, onde as propriedades do objeto fiquem preservadas e as condições de iluminação sejam semelhantes às existentes no processo de aquisição das imagens (STEFFEN *et al.*).

Os dados de campo foram colhidos no dia 23 de abril de 2008 e obtidos colocando-se a unidade detectora a uma altura tal que abranja toda a área a ser medida e perpendicularmente à mesma. O espectrorradiômetro utilizado tem um campo de visada de 25°. Dessa forma, gerou-se uma tabela para várias dimensões de áreas cobertas pelo espectrorradiômetro, relacionados com a altura da unidade detectora. Para cada classe informacional definida, as medidas efetuadas com o espectrorradiômetro foram feitas na placa de referência e, em seguida, no alvo, mantendo a mesma geometria (posição do alvo e do sensor) e condição de iluminação.

As medidas das observações de campo, no que diz respeito às condições atmosféricas, foram desenvolvidas de acordo com o sugerido por Steffen *et al.* (1996), ou seja, com a presença de no máximo 20% de cobertura de nuvens e jamais com o sol encoberto ou parcialmente encoberto.

3.3.4. METODOLOGIA DO TRABALHO

A metodologia adotada nesse trabalho consistiu em se obter no campo, sobre o pavimento asfáltico, as curvas espectrais das seguintes classes informacionais representativa das condições do pavimento: a) RA novo e em bom estado; b) RA velho e em bom estado; c) RA com baixo grau de deterioração; d) RA com alto grau de deterioração.

Com os dados de campo, procedeu-se ao seu processamento. A dificuldade para medir a reflectância espectral através dos fluxos incidente e refletivo origina a medida de uma grandeza equivalente que é o *fator de reflectância*, sendo este a razão entre a radiância do objeto e a radiância de uma superfície lambertiana⁶ ideal, denominada placa de referência (ou placa padrão), nas mesmas condições de iluminação e medição. O espectrorradiômetro mede a intensidade de radiação refletida no alvo e não a reflectância do alvo.

Utilizando a Equação 3.3 e através das leituras efetuadas no alvo e na placa de referência, obtém-se o fator de reflectância do alvo.

$$FR_{\lambda} = \left(\frac{L_{\lambda}^a}{L_{\lambda}^p} \right) \cdot 100 \cdot VT_{\lambda}^p \quad (3.3)$$

Onde:

FR_{λ} - é o fator de reflectância no comprimento de onda λ (%);

VT_{λ}^p - valor tabelado em função do comprimento de onda (pl. referência);

L_{λ}^a - é a intensidade da radiação refletida no alvo;

L_{λ}^p - é a intensidade da radiação refletida na placa de referência.

⁶ *Superfície lambertiana* é uma superfície plana que reflete a luz incidente com a mesma intensidade em todas as direções.

Utilizou-se o software Excel para o processamento dos dados e a geração das curvas espectrais dos padrões levantados no campo.

Com as curvas espectrais no intervalo entre 350 e 2.500 nm, procurou-se analisar se uma ou mais faixas dentro do intervalo das curvas espectrais seriam capazes de discriminar os padrões analisados. Dessa forma, seria possível indicar a construção (ou a aquisição) de um sensor para operar exclusivamente na faixa determinada, tornando-o mais barato e, conseqüentemente, de mais fácil aquisição.

Para facilitar a análise das curvas espectrais usou-se operações de subtração entre as curvas espectrais dos padrões analisados, adotando-se o RA novo e bom como referência.

3.3.5. RESULTADOS E DISCUSSÕES

Essa seção foi dividida em 2 subseções. A primeira subseção faz a análise de curvas espectrais de 350 a 2.500 nm para a discriminação de padrões de pavimentos asfálticos. A segunda subseção apresenta e discute características de várias curvas espectrais do pavimento asfáltico.

3.3.5.1. ANÁLISE DE CURVAS ESPECTRAIS DE 350 A 2.500 NM PARA A DISCRIMINAÇÃO DE PADRÕES DE PAVIMENTOS ASFÁLTICOS

As curvas espectrais dos 4 padrões analisados estão apresentadas na Figura 3.11, a saber: a) RA novo e em bom estado; b) RA velho e em bom estado; c) trinca com baixo grau de deterioração; d) trinca com alto grau de deterioração. Esses padrões foram escolhidos porque são bem representativos de defeitos em pavimento asfáltico.

Visualmente percebe-se que tanto no início das curvas, aqui denominado por “Faixa 1”, quanto no final das curvas, denominado por “Faixa 2”, discrimina-se mais facilmente as classes analisadas. Assim, procurou-se definir os valores das bandas, concluindo que a Faixa 1 vai de 350 a 800 nm e a Faixa 2 de 1960 a 2260 nm.




Figura 3.11 - Curvas espectrais dos 4 padrões analisados

A análise fica um pouco confusa porque existem muitos picos nas curvas, na “Faixa 1” no início e final da banda e na “Faixa 2” no início. Para amenizar esse problema optou-se em fazer operações de subtração entre as curvas, adotando-se o RA novo e bom como referência. A Figura 3.12 mostra as curvas obtidas nas operações de subtração: a) [RA velho] - [RA novo]; b) [trinca com baixo grau] - [RA novo]; c) [trinca com alto grau] - [RA novo]. Mesmo assim, ainda há alguma dificuldade na análise, principalmente na “Faixa 2”.




Figura 3.12 - Curvas espectrais obtidas por operação de diferença

Uma nova tentativa foi feita, agora, procurando-se estreitar as bandas das faixas, fixando a “Faixa 1” com largura de 450 a 755 nm e a “Faixa 2” com largura de 2100 a 2220 nm. A Figura 3.13 apresenta o resultado dessa fase,

mostrando agora uma boa discriminação nas duas faixas finais.




Figura 3.13 - Curvas espectrais obtidas por operação de diferença

Sabe-se que um sistema sensor tem preço mais elevado à medida que se afasta da região do visível (400 - 700 nm) e por ser a 2ª faixa (2100-2220) relativamente estreita, conclui-se que um sistema sensor que opere basicamente na faixa do visível atenderia sem maiores problemas ao questionamento desse trabalho.

3.3.5.2. CURVAS ESPECTRAIS DO PAVIMENTO ASFÁLTICO NO INTERVALO DE 400 A 755 NM

Definido o intervalo que melhor discrimina os padrões de RA, apresentam-se na Figura 3.14 curvas espectrais de algumas classes informacionais, em um total de 8 classes.

Tratando-se do mesmo padrão, porém nas condições de seco e molhado, a curva espectral “molhado” fica transladada para baixo em relação a curva espectral “seco” (veja padrões 1 e 2, 3 e 4, 5 e 6 - Figura 3.14).

Há dois tipos bem definidos de curvas espectrais, determinados pelos comportamentos espectrais dos materiais que compõem os padrões observados no campo: a) curvas espectrais do material RA - bom ou ruim (veja padrões de 1 a 7 - Figura 3.14); b) curvas espectrais do material solo - buracos (veja padrão 8 - Figura 3.14).






Num / Padrão	Imagem	Curva de Reflectância
01 RA novo e seco		
02 RA novo (molhado)		
03 RA velho em bom estado (seco)		
04 RA velho em bom estado (molhado)		
05 Trinca couro de jacaré (seca)		
06 Trinca couro de jacaré (molhada)		
07 Remendo antigo (seco)		
08 Panela (seca)		

Figura 3.14 - Curvas de reflectância no intervalo de 400 a 755 nm para vários padrões de RA

O RA novo reflete menos que o RA velho, sendo sua curva espectral com níveis de reflectância mais baixo que o RA velho (veja padrão 1 e 2, 3 e 4 - Figura 3.14). A explicação para esse fato é que com o envelhecimento do RA, a superfície do revestimento é menos viscosa e mais propensa a danos estruturais e sua deterioração inicia, expondo as pedras da mistura. O processo continua até que a componente pedra domina a superfície do RA, diminuindo as absorções e resultando em um aumento da reflectância na superfície.

As curvas espectrais das trincas couro de jacaré têm uma aparência bem similar às curvas espectrais do RA novo (veja padrão 1 e 2, 5 e 6 - Figura 3.14).

O remendo antigo e seco tem sua curva espectral similar ao RA antigo e seco (veja padrão 3 e 4, 7 - Figura 3.14).

3.4. RESUMO DO CAPÍTULO

Como síntese desse capítulo, fez-se uma abordagem sobre radiometria, aplicando-se o conhecimento dessa área na obtenção das curvas espectrais de padrões de pavimentos asfálticos, utilizando um espectrorradiômetro que opera na faixa de 350 a 2.500 nm.

A principal conclusão do experimento desenvolvido nesse capítulo é que as diferenças entre padrões de RA podem ser usadas para discriminar padrões da superfície dos pavimentos asfálticos e que um sensor que opere na faixa de 400 a 755 nm atenderia satisfatoriamente para discernir as diferentes condições de manutenção dos pavimentos asfálticos.

Na sequência, propõe-se abordar no Capítulo 4, estratégias para a discriminação de defeitos superficiais em pavimento asfáltico com o uso de imagens multiespectrais. Para tanto, propõe-se fazer um estudo de viabilidade para a extração de características das imagens da superfície asfáltica, através da análise das informações espectrais da imagem.

CAPÍTULO 4

DISCRIMINAÇÃO DE DEFEITOS SUPERFICIAIS EM PAVIMENTO ASFÁLTICO COM O USO DE IMAGENS MULTIESPECTRAIS

No Capítulo 2, abordou-se o levantamento de defeitos superficiais em pavimentos asfálticos. No Capítulo 3, o enfoque foi a obtenção de curvas espectrais de padrões das superfícies dos pavimentos asfálticos em variadas condições de conservação. Agora, nesse capítulo, aborda-se o desenvolvimento de estratégias e procedimentos para o reconhecimento automático de padrões de defeitos em superfícies asfálticas com o uso de imagens multiespectrais. Dois experimentos foram desenvolvidos e os resultados apresentados: um utilizando imagem orbital de altíssima resolução e outro com imagem terrestre, ambas multiespectrais.

4.1. INTRODUÇÃO

As imagens digitais são matrizes numéricas, sobre as quais é possível a realização de diversas operações e análises.

Basicamente, depois do pré-processamento das imagens duas abordagens são possíveis: *análise qualitativa*, na qual se utilizam operações de filtragem e realce de imagens para melhorar a qualidade visual dessas imagens, com a finalidade de ajudar na interpretação visual por analistas e, *análise quantitativa*, na qual se utilizam algoritmos computacionais para extrair informações automaticamente das imagens digitais.

No escopo dessa pesquisa será utilizada tanto a análise quantitativa quanto a qualitativa de imagens, com vista à detecção de defeitos nas superfícies de pavimentos asfálticos.

O objetivo do reconhecimento de padrão é detectar, identificar e extrair elementos presentes em uma cena. Trata-se de uma tarefa complexa do ponto de vista computacional, exigindo técnicas sofisticadas para a obtenção de bons resultados (CRÓSTA, 1993).

O sistema automático de reconhecimento de padrão tem aplicações diversas como, por exemplo, no reconhecimento de voz, no reconhecimento de caracteres, no reconhecimento de caligrafia, etc.

Em imagens, a partir da definição das classes informacionais, o sistema automático de reconhecimento de padrão tem por objetivo obter a classificação dessas classes.

Segundo Vieira (2000), um sistema automático de reconhecimento de padrão é composto das etapas como apresentadas na Figura 4.1.




Figura 4.1 - Etapas de um sistema automático de reconhecimento de padrão

As etapas que aparecem na Figura 4.1 são explicadas nas próximas seções.

4.2. DESCRIÇÃO DO OBJETO

A *Descrição do Objeto* é a etapa de definição das medidas ou das variáveis discriminatórias, cujo objetivo é representar computacionalmente os objetos de interesse.

No caso de imagens do pavimento asfáltico, as variáveis discriminatórias consideradas nesta tese para a descrição dos defeitos são: dados espectrais (imagem multiespectral) e a textura (imagem monocromática).

4.3. EXTRAÇÃO DE CARACTERÍSTICAS

A *Extração de Características* é a etapa onde se seleciona um subconjunto das medidas ou variáveis discriminatórias da etapa anterior que

melhor discriminem os objetos de interesse.

No caso de imagens do pavimento asfáltico, para a extração de características serão utilizados os seguintes passos: a) tratando-se de imagens multiespectrais e definida as classes informacionais, a extração será feita *pixel a pixel* em cada banda (dados espectrais) correspondente a cada classe informacional; b) se a imagem for monocromática, a extração de características será feita através da aplicação de uma transformada sobre a imagem.

4.4. REGRA DE DECISÃO

A *Regra de Decisão* é a etapa da definição do(s) classificador(es) utilizado(s).

A classificação da imagem digital objetiva identificar automaticamente os objetos segmentados na imagem. Nessa fase, através da regra de decisão escolhida, uma imagem digital é transformada em uma imagem temática.

Na Figura 4.2, tem-se em (a) uma imagem de um trecho de pavimento asfáltico onde se observa trincas (2 tipos diferentes) e buraco (panela); em (b) tem-se a imagem classificada.




Figura 4.2 - Classificação de uma imagem de RA

As técnicas de classificação digital implicam na implementação de um processo de decisão para que o computador possa atribuir certo conjunto de pontos da imagem (*pixels*) a uma determinada classe. Tais procedimentos tornam o processo de reconhecimento de características do alvo em estudo menos subjetivo e com maior potencial de repetição em situações subseqüentes.

Devido à relevância do assunto, na seção seguinte aborda-se os classificadores multiespectrais, dando ênfase ao classificador estatístico MaxVer e às Redes Neurais Artificiais, que são as regras de decisão usadas nos experimentos desse capítulo.

4.4.1. CLASSIFICADORES MULTIESPECTRAIS

Classificadores multiespectrais são algoritmos computacionais utilizados na extração da informação de imagens multiespectrais, para reconhecer padrões e objetos homogêneos.

Em uma imagem multiespectral de uma cena, as características espectrais de cada *pixel* são suas coordenadas espaciais (x,y) e espectral (VN) – valor numérico nas diferentes bandas espectrais, que corresponde ao brilho do *pixel*. Assim, uma imagem de k bandas, contém k valores numéricos associados a cada *pixel*, sendo um para cada banda espectral.

A Figura 4.3 apresenta uma imagem de RA em 3 bandas espectrais diferentes. Em (a) tem-se a imagem na banda do azul (aproximadamente 400 a 500 nm); em (b) na banda do verde (aproximadamente 500 a 600 nm); em (c) na banda do vermelho (aproximadamente 600 a 700 nm). Todas as imagens são apresentadas em tons de cinza, e no caso de imagem em 8 bits, os valores dos *pixels* variam de 0 a 255.




Figura 4.3 - Imagem multiespectral de um RA composta de 3 bandas

As etapas de uma classificação multiespectral, de acordo com o tipo de treinamento, são apresentadas na Figura 4.4 e descritas em seguida.




Figura 4.4 - Etapas da classificação multiespectral (fase de treinamento)

4.4.1.1. CLASSIFICAÇÃO SUPERVISIONADA

Classificação supervisionada é o processo de utilizar amostras conhecidas, representativa de cada classe, denominadas *amostras de treinamento*, para treinar e classificar os *pixels* desconhecidos. O conhecimento prévio dessas amostras é feito por análise de campo, fotos aéreas, experiência pessoal ou mapas.

De uma maneira geral, as etapas utilizadas na classificação supervisionada são mostradas na Figura 4.5.




Figura 4.5 - Etapas da classificação supervisionada

Na Etapa 1, definem-se as classes que se deseja identificar na imagem, tais como: RA bom, trinca, panela, exsudação, etc.

Na Etapa 2, selecionam-se e coletam-se as amostras de treinamento representativas de cada uma das classes informacionais.

A Etapa 3 é denominada *treinamento*, na qual se utilizam as amostras de treinamento para estimar os parâmetros usados pelo classificador.

A Etapa 4 é a *classificação propriamente dita*, na qual o classificador rotula cada *pixel* como pertencente a uma das classes (definida na etapa 1), utilizando os parâmetros estimados na Etapa 3. O resultado dessa etapa é uma

imagem temática que será transformada em um desenho temático, mostrando o resultado da classificação.

A Etapa 5 é a etapa de *avaliação da imagem temática* obtida na Etapa 4, utilizando uma *imagem de referência*, na qual os *pixels* de uma classe de ambas as imagens são comparados entre si, nas mesmas posições. Utilizam-se técnicas de amostragens, através de *amostras testes*¹, cujo critério de reconhecimento é o mesmo das amostras de treinamento. O resultado da comparação das imagens (classificada e de referência) é a *matriz de contingência* ou *matriz de erros*, cujas colunas representam as classes da imagem de referência e as linhas representam as classes obtidas na classificação - Tabela 4.1.

Tabela 4.1 - Exemplo de uma Matriz de Erros
Fonte: adaptado de Landgrebe (2003)

Imagem classificada	Imagem de referência				
	Classe 1	Classe 2	Classe 3	Total	E.C.(%)
Classe 1	45	10	6	61	26,2
Classe 2	2	15	1	18	16,7
Classe 3	6	5	52	63	17,5
Total	53	30	59	142	
E.O.(%)	15,1	50,0	13,5		

Extraem-se da matriz de contingência pelo menos quatro índices que são usados para avaliar a exatidão da classificação. São eles: a) índice Kappa ($\hat{K}$) - índice de concordância; b) exatidão global (EG); c) erro de omissão (EO); d) erro de comissão (EC).

A Tabela 4.2 apresenta os índices citados, suas definições e fórmulas para cálculos.

¹ *Amostras testes* são conjuntos de *pixels* pertencentes às classes informacionais definidas e que são identificadas antes da classificação propriamente dita, não devendo fazer parte das amostras de treinamento.

Tabela 4.2 - Índices derivados da matriz de contingência

Índice	Expressão	Definição
Kappa ($\hat{K}$)	$\hat{K} = \frac{EG - VE}{1 - VE}$ EG - exatidão global VE - valor esperado	VE – valor calculado usando as marginais da matriz de erro
Exatidão Global (EG)	$EG = \frac{\sum DP}{TP}$	$\sum DP$ – somatório da diagonal principal da matriz de contingência TP – somatório de todos os elementos da matriz de contingência
Erro de omissão (EO)		<i>pixels</i> que deveriam ser classificados em uma classe são classificados como pertencente a outra(s) classe(s)
Erro de comissão (EC)		<i>pixels</i> são classificados erroneamente em outra (s) classe(s), quando deveriam ser assinalados na classe correta

Uma imagem temática de boa qualidade possui $EG \geq 85\%$.

A Tabela 4.3 apresenta os valores do índice Kappa, que varia de 0 (zero) a 1 (um), com as denominações correspondentes ao desempenho da classificação.

Tabela 4.3 - Valores do índice Kappa e correspondente desempenho da classificação
Fonte: Congalton e Mead (1991)

$Kappa \leq 0,2$	Péssimo
$0,2 \leq Kappa \leq 0,4$	Razoável
$0,4 \leq Kappa \leq 0,6$	Bom
$0,6 \leq Kappa \leq 0,8$	Muito bom
$0,8 \leq Kappa \leq 1,0$	Excelente

Outros índices também são derivados da matriz de erro e utilizados na avaliação da classificação, cujas fórmulas podem ser observadas em Congalton e Green (1999). São eles: variância de kappa - $Var(\hat{K})$ e o teste estatístico Z.

4.4.1.2. CLASSIFICAÇÃO NÃO-SUPERVISIONADA

Quando se utilizam algoritmos para reconhecer classes na imagem, sem

a interferência *a priori* do usuário, o treinamento é dito não-supervisionado. O classificador agrupa os *pixels* em diferentes classes de acordo com determinados critérios estatísticos pré-definidos, basicamente, alguma medida de similaridade entre classes, ou seja, *pixels* serão agrupados numa mesma classe se a medida de similaridade entre eles for atendida (FONSECA, 2000).

Depois do conjunto de *pixels* (região) serem classificadas (normalmente por uma sequência numérica), o usuário muda o nome das classes para uma denominação que faça sentido.

Para encerrar essa seção, cabe informar que os classificadores podem ser *pixel a pixel* ou *por regiões*.

Os *classificadores pixel a pixel* utilizam somente a informação espectral de cada *pixel* para achar regiões homogêneas na imagem (VIEIRA, 2000).

Os *classificadores por região* consideram propriedades de grupos de *pixels*, como por exemplo, a média das informações espectrais, informações texturais, etc (VIEIRA, 2000).

4.4.1.3. CLASSIFICADOR MAXVER

O classificador MaxVer (Máximo Verossimilhança) é um algoritmo estatístico e paramétrico, bastante conhecido da comunidade científica e utilizado na classificação de imagens multiespectrais. Utiliza a média e co-variância das amostras de treinamento como parâmetro para calcular a probabilidade de um *pixel* desconhecido pertencer a uma ou outra classe informacional (VIEIRA, 2000).

Para a classificação de um *pixel* desconhecido o classificador MaxVer utiliza FDP's, determinando a probabilidade desse *pixel* pertencer a uma dada classe. Após avaliar essa probabilidade para todas as classes definidas, o *pixel* analisado é rotulado à classe que tenha a maior probabilidade ou, no caso de probabilidade muito baixa (limiar), a nenhuma classe analisada.

Por exemplo, analisando as duas classes (classe 1 e classe 2) na Figura 4.6, suas distribuições de probabilidade representam a probabilidade de um *pixel* pertencer a uma ou outra classe, dependendo, naturalmente, da posição do *pixel* em relação às distribuições. O *pixel* (1) é classificado como classe 1; o *pixel* (2) é classificado como classe 2; o *pixel* (3) - área hachurada, apesar de pertencer à classe 1 é classificado como classe 2, devido ao limite de aceitação (limiar).




Figura 4.6 - Exemplo de limite de aceitação utilizando o classificador MaxVer
Fonte: adaptado de Crósta (1993)

Um limite de aceitação de 98% significa que 98% dos *pixels* são considerados e 2% são ignorados, naturalmente, os de menor probabilidade (por exemplo, *pixels* localizados entre duas classes). Já um limite de aceitação de 100% todos os *pixels* serão classificados, não havendo rejeição.

A regra de decisão considera as classes com as mesmas probabilidades de ocorrência - classes equiprováveis (VIEIRA, 2000), sendo essa regra a utilizada nesse trabalho.

Regra de decisão: assinala-se X na classe C, se e somente se, $P_c \geq P_i$,

Onde:

$i = 1, 2, 3, \dots, m$, as possíveis classes;

P_c - probabilidade do vetor X ser classificado na classe C;

Pi - probabilidade do vetor X ser classificado em qualquer outra classe.

A função de densidade de probabilidade é dada pela Equação 4.1.

$$P_c = (-0,5 \log_e(\det V_c)) - (0,5(X - M_c)^T (V_c)^{-1} (X - M_c)) \quad (4.1)$$

Onde:

Mc - o vetor das médias para cada classe C;

Vc - matriz de covariância da classe C contemplando todas as bandas (k, . . . ,L);

X - vetor das *n* medidas dos *pixels* desconhecidos.

Um outro tipo de classificador, porém não-paramétrico, robusto e já bastante estudado e, portanto, documentado, são as Redes Neurais Artificiais (RNA) e que é abordado na seção seguinte.

4.4.1.4. REDES NEURAIS ARTIFICIAIS

As RNAs são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência.

Segundo Haykin (2001), pelo menos em dois aspectos as RNAs assemelham-se ao cérebro humano: o processo de conhecimento é adquirido pela rede por meio de um processo de aprendizado e as intensidades das conexões entre neurônios, denominados pesos sinápticos, são usados para armazenar conhecimento.

As RNAs apresentam, devido às suas características típicas, a habilidade de adaptação e aprendizagem pelo ambiente, o que lhes permite lidar com dados imprecisos e situações indefinidas.

No caso de serem treinadas razoavelmente, as RNAs têm a habilidade

de generalizar ao serem apresentadas a novos padrões que não estavam presentes no processo de treinamento.

Com base no exposto, observa-se que a modelagem das RNAs tem como objetivo fornecer meios para que o algoritmo seja capaz de extrair características dos dados, a partir de um conjunto supervisionado de treinamento e, assim, possa armazenar o conhecimento adquirido e aplicá-lo em situações reais.

A utilização de uma RNA na solução de uma tarefa passa, antes de tudo, por uma fase de aprendizagem (ou treinamento), quando a rede extrai informações relevantes de padrões de informação apresentados para ela, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, principalmente dos pesos das conexões entre as unidades de processamento (neurônios artificiais), que guardam, ao final do processo, o conhecimento que a rede adquiriu sobre o problema em questão.

A Figura 4.7 apresenta, em (a) uma rede de neurônios biológicos e em (b) uma rede neural artificial, com algumas denominações usuais.




Figura 4.7 - Rede de neurônios
Fonte: (a) - Gleriani (2004)

Outro aspecto a destacar é que uma rede neural pode aceitar diferentes tipos de dados de entrada, como por exemplo, integração de dados multi-sensores.

Para encerrar essa breve introdução, cabe ressaltar que entre as

vantagens do uso das RNAs está a sua capacidade de generalização e a facilidade de processar e interpretar grandes quantidades de dados.

(i) Funcionamento de um neurônio artificial

Um modelo de neurônio artificial visa exercer características similares ao neurônio biológico. Para tanto, um neurônio artificial possui uma estrutura, no que diz respeito à forma de processamento, semelhante ao neurônio biológico.

A Figura 4.8 apresenta o esquema típico de um neurônio artificial, sendo suas operações descritas assim: a) os sinais (dados) são apresentados aos neurônios (x_i); b) cada sinal é multiplicado por um peso (w_i), que indica a influência do neurônio (excitatória ou inibitória); c) o neurônio K recebe os sinais ponderados dos neurônios (x_i), indicando um nível de atividade; d) pode ocorrer a entrada do *bias* (θ_k), que é um termo independente na somatória dos pesos, cuja função é aumentar ou diminuir a entrada líquida na função de ativação - Equação 4.2; f) a função de ativação (φ) serve para normalizar os dados de saída dos neurônios (HAYKIN, 2001).

$$y_{entrada} = w_1 * x_1 + w_2 * x_2 + w_3 * x_3 + \dots + w_n * x_n + \theta_k \quad (4.2)$$







Figura 4.8 - Esquema típico de um neurônio artificial
Fonte: adaptado de Gleriani (2004) e Santos Jr (2006)

Segundo Santos Jr (2006), as funções de ativação mais utilizadas são a linear, a logística e a tangente hiperbólica, sendo as duas últimas funções do tipo sigmoidal.

Na Tabela 4.4, têm-se as 3 funções citadas, os intervalos que os valores

de saída podem assumir e os gráficos respectivos. O valor x nas fórmulas da Tabela 4.4 corresponde ao somatório ponderado de cada contribuição do neurônio da camada de entrada, multiplicado pelos pesos do *link* que unem esses neurônios.

Tabela 4.4 - Principais funções de ativação (ou transferência)
Fonte: adaptado de Santos Jr (2006)

Função	Linear	Logística	Tangente Hiperbólica
	$Y = a.x$	$Y = \frac{1}{1 + e^{-x}}$	$Y = \frac{1 - e^{-x}}{1 + e^{-x}}$
Domínio	$[-\infty, +\infty]$	$[0, 1]$	$[-1, 1]$
Gráfico			

(ii) Principais topologias de redes neurais

A topologia de uma RNA, também denominada de arquitetura, é a forma como os neurônios são organizados na RNA. Ela afeta o desempenho da rede, assim como as aplicações para as quais a rede está sendo proposta. A arquitetura está intimamente ligada ao algoritmo de aprendizagem usado para o treinamento da rede.

De acordo com Venturieri e Santos (1998), as RNAs são organizadas de acordo com o número de camadas que compõem a sua estrutura topológica. Dessa forma, existem as redes neurais de camadas simples, constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes multicamadas, formadas pela combinação de várias redes de camada simples.

Ao longo do tempo, várias topologias foram definidas para diferentes tipos de aplicações. Contudo, alguns modelos destacaram-se com o tempo e suas aplicações foram tornando-se frequentes.

Na Figura 4.9, são apresentadas algumas topologias usuais, sendo que o modelo utilizado nesta tese é o *Multi Layer Perceptron* (MLP), também denominado *Modelo de Múltiplas Camadas*, sendo considerado o modelo de

uso mais corriqueiro e, portanto, mais bem documentado. As redes MLPs têm sido usadas nas mais diversas áreas: sensoriamento remoto, engenharia elétrica, engenharia civil, medicina, etc.




Figura 4.9 - Arquiteturas típicas de modelos de RNAs
Fonte: adaptado de Santos Jr (2006)

O modelo MLP é formado por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, todas contendo neurônios - Figura 4.10. Os neurônios da camada de entrada não são unidades processadoras e sim unidades distribuidoras dos valores de entrada para a primeira camada oculta e a camada de saída é que emite os resultados para a amostra estudada (MOTTA, 2004).




Figura 4.10 - Representação esquemática da arquitetura (topologia) de uma rede MLP

(iii) Etapas da classificação supervisionada utilizando uma rede MLP

As redes MLP possuem aprendizado supervisionado e, de uma maneira

geral, as etapas utilizadas na classificação supervisionada de uma rede MLP são mostradas na Figura 4.11.




Figura 4.11 - Etapas da classificação supervisionada de uma rede MLP

Na Etapa 1, definem-se as classes que se deseja identificar na imagem, tais como: RA bom, trinca, panela, exsudação, etc.

Na Etapa 2, selecionam-se e coletam-se amostras conhecidas que serão utilizadas na etapa de treinamento da rede (ou aprendizado), na etapa de teste da rede e também na etapa de validação dos pesos obtidos.

Na Etapa 3, determina-se como será feita a entrada de dados, como ocorrerá a saída dos resultados da rede e, finalmente, a topologia da rede. Quanto à determinação da topologia da rede, especificamente o número de neurônios da camada oculta, Vieira (2000) sugere o seguinte procedimento desenvolvido por Hirose *et al.* (1991), baseado no comportamento do erro global durante a fase de treinamento, na qual se espera que este evolua para valores cada vez menores: começar com um neurônio na camada oculta e, após um determinado número de ciclos, se o erro global não diminuir, por exemplo, mais que 1% de seu valor anterior, encerra-se o treinamento e adiciona-se um novo neurônio à camada oculta. Fazer o treinamento com a nova topologia, repetindo o procedimento já explicado, até que a rede convergir para um valor do erro global aceitável. Agora, faz-se o procedimento contrário, retirando neurônios (1 de cada vez e na sequência contrária - do último para o primeiro) até a rede não convergir satisfatoriamente para um determinado número de ciclos. A melhor topologia é aquela anterior à não convergência.

Na Etapa 4, realizam-se os cálculos para o ajuste dos pesos da rede, que definirão o menor erro em relação os dados originais. É possível nessa fase ocorrer problemas, tais como *overflow da função de erro*² e *saturação dos neurônios*³ e que devem ser evitados para que a rede fique bem treinada. O algoritmo de retropropagação de erros (RPE) tem sido o principal algoritmo utilizado para o treinamento de uma rede MLP (HAYKIN, 2001).

Na Etapa 5, é feita a validação da rede, utilizando as amostras independentes de teste para verificar a capacidade de generalização da rede que foi treinada na etapa anterior.

Na Etapa 6, gera-se a imagem classificada.

(iv) Parâmetros observáveis em uma rede MLP

Definidos a arquitetura da rede MLP e o algoritmo RPE como sendo o utilizado para o treinamento da rede, segue a explicação de alguns parâmetros que devem ser observados em uma rede MLP, apresentados na Figura 4.12.




Figura 4.12 - Parâmetros de análise em uma rede MLP

Quanto ao *tamanho da amostra*, ou seja, o número mínimo de amostras por classe, parece não haver um consenso (GLERIANI, 2004). Nesse trabalho, procurou-se adotar o número mínimo de amostras por classe, como sendo trinta vezes o número de variáveis discriminatórias. Na prática, as amostras de teste podem ser adquiridas com a metade da quantidade das amostras de treinamento, por classe.

² *Overflow da função de erro* ocorre nas variáveis responsáveis pelo cálculo dos erros;

³ *Saturação dos neurônios* ocorre quando um dos neurônios atinge valores muito próximos do limite da função de ativação, instabilizando a rede. O valor do neurônio praticamente não modifica, mesmo com as alterações dos pesos.

Quanto à *estrutura de dados*, podem ser por entrada simples ou por janelas (3x3, 5x5, etc) ao redor do *pixel*. Existem relatos na literatura, tais como, Bischof *et al.* (1992), Paola e Schowengerdt (1997), He e Collet (1999), que utilizaram entrada por janelas quando o assunto é a análise da textura. Já, se a análise é das características espectrais, a entrada simples é a mais usual.

Quanto à *normalização dos dados de entrada*, segundo Bishop (1995), quando os dados das variáveis discriminatórias diferem bastante, sua normalização é muito útil, pois dependendo das medidas de cada variável, elas podem ter valores que diferem bastante, sendo comum não refletir suas importâncias relativas. Bishop (1995) propõe fazer a normalização dos dados de entrada através de uma transformação linear, assim: um conjunto de dados s , com N elementos, variáveis x_s , média μ_s e desvio padrão σ_s seja normalizado para um novo conjunto de valores X_s . Utilizam-se as Equações 4.3, 4.4 e 4.5 para o cálculo desses parâmetros. O conjunto de dados resultante X_s terá média zero e desvio padrão igual a um.

$$X_s = \frac{x_s - \mu_s}{\sigma_s} \quad (4.3)$$

$$\mu_s = \frac{1}{N} \sum_{s=1}^N x_s \quad (4.4)$$

$$\sigma_s = \sqrt{\frac{1}{N-1} \sum_{s=1}^N (x_s - \mu_s)^2} \quad (4.5)$$

Miller *et al.* (1995) sugerem um re-escalamento dos dados definidos no intervalo entre -1 e 1 e em função dos valores máximo - MAX e mínimo - MIN do conjunto de dados originais, uma vez que utilizaram a função de ativação tangente hiperbólica - Equação 4.6.

$$X_s = 2 \left(\frac{x_s - \text{MIN}}{\text{MAX} - \text{MIN}} \right) - 1 \quad (4.6)$$

Os *parâmetros ligados ao algoritmo RPE* são a taxa de aprendizagem, a função de ativação, o erro médio quadrático e momentum.

A *taxa de aprendizagem* corresponde à velocidade de ajuste dos pesos, sendo seu valor entre 0 e 1; valores próximos de 1 fazem a rede convergir mais rapidamente (treinamento rápido), porém há a possibilidade de tornar a rede instável; valores próximos de zero tornam a convergência da rede mais demorada (treinamento lento), porém ocorre maior estabilidade da rede.

A *função de ativação* mais utilizada é a logística, fazendo com que a saída de um neurônio seja escalonada entre 0 (zero) e 1 (um). Segundo Heinen (2002), a função logística, no processo de aprendizagem, devido à sua curvatura especial, gera certa estabilidade no sistema, depois que o valor do neurônio se encontra próximo a um dos extremos.

Referindo ao erro médio quadrático, constata-se que, para um bom treinamento da rede, o erro obtido com os dados de teste (linha verde) deve ficar próximo com o erro obtido com os dados de treinamento (linha vermelha), conforme Figura 4.13. Quando não ocorre um treinamento satisfatório, o erro dos dados de teste (linha azul) afasta-se do erro dos dados de treinamento, mesmo se ele continuar a baixar.




Figura 4.13 - Gráfico de erro de acordo com a interpolação
Fonte: Santos Jr (2006)

O *momentum* é um parâmetro utilizado, principalmente, para acelerar a aprendizagem da rede sem introduzir oscilação na mesma, modificando os pesos antigos (relativos a 1) e utilizando-os como parâmetros para os novos pesos.

Quanto ao *número de iterações* (ciclos) na etapa de treinamento, atenta-se que, uma rede sobre-treinada fica muito especializada, perdendo sua capacidade de generalização. Segundo Haykin (2001), o número de ciclos ideal é obtido pelo método de *validação cruzada com parada antecipada*, que é descrita a seguir.

A Figura 4.14 apresenta duas curvas de erro: uma utilizando as amostras de treinamento e a outra com amostras de validação⁴. Na curva de erro, utilizando amostras de treinamento, observa-se que o erro cai rapidamente e depois vagarosamente. Já na curva de erro, utilizando amostras de validação, o erro cai até um certo valor e depois começa a crescer, denotando no ponto mínimo, o ideal de parada de treinamento das amostras (número de ciclos). A partir deste ponto de mínimo, a RNA começa a ficar específica para os dados na qual foi treinada.




Figura 4.14 - Ponto de parada antecipada baseado na validação cruzada
Fonte: Gleriani (2004)

4.5. AVALIAÇÃO DO MODELO

A Avaliação do Modelo é a etapa em que se verifica a precisão da identificação do sistema automático de reconhecimento de padrão. Na maioria dos estudos de classificação, a exatidão do resultado é avaliada por meio da matriz de contingência (LILLESAND e KIEFER, 1994). As características e índices extraídos dessa matriz já foram descritas na subseção 4.4.1.1.

4.6. MATERIAIS E MÉTODOS

Desenvolveram-se dois experimentos, na tentativa de estabelecer estratégias e procedimentos para o reconhecimento automático de padrões de defeitos em superfícies asfálticas com o uso de imagens. O primeiro experimento utiliza imagem orbital de altíssima resolução e o segundo

⁴ *Amostras de validação* é uma pequena quantia da amostra de teste e que é usado pela RNA para classificar *a posteriori*.

experimento, imagem terrestre, ambas multiespectrais.

4.6.1. PRIMEIRO EXPERIMENTO

4.6.1.1. CONTEXTUALIZAÇÃO E OBJETIVO

Poucas iniciativas aparecem na literatura sobre detecção de defeitos em superfícies asfálticas utilizando sensoriamento remoto e o uso de classificadores multiespectrais. Devido ao estágio das resoluções espaciais das imagens de satélite, mesmo as de altíssima resolução, como imagens dos sensores *IKONOS II* e *QuickBird 2*, sabe-se que identificar defeitos sobre o pavimento é uma tarefa com um nível de dificuldade muito grande.

Este experimento tem por objetivo analisar a possibilidade de se fazer a detecção de defeitos superficiais nos pavimentos asfálticos com o uso do sensoriamento remoto, através de imagem orbital de altíssima resolução, utilizando como regra de decisão os classificadores MaxVer e redes neurais artificiais (RNA) no reconhecimento de padrões, de forma a minimizar custos e tempos de levantamentos no campo, assim como melhorar a repetitividade dos dados levantados.

4.6.1.2. DESCRIÇÃO DA ÁREA DO EXPERIMENTO

A área do experimento corresponde a dois trechos de rodovias situadas no município da cidade de Viçosa (MG), conforme Figura 4.15. Um trecho foi da BR-120, que liga Viçosa a Teixeiras e o outro foi da mesma BR, que liga Viçosa a Coimbra. Na escolha dessa área prevaleceu a disponibilidade de uma imagem *QuickBird 2* da região e os trechos foram selecionados por apresentarem uma boa identificação visual das classes informacionais em estudo.

4.6.1.3. METODOLOGIA DO TRABALHO

A metodologia adotada consistiu em, inicialmente, definir as classes informacionais mais representativas que poderiam ser observadas na imagem - Figura 4.15, assim: a) RA bom; b) RA ruim; c) sombra no RA; e, d) veículos

sobre o RA. A expressão “RA ruim” é para caracterizar RAs com defeitos. Embora a pesquisa seja para distinguir problemas superficiais no RA, as sombras no RA e veículos sobre o RA são feições que teriam que ser avaliadas, pois elas interferem na análise sobre o RA bom e RA ruim. Assim, tem-se que extrair previamente essas feições do pavimento para poder fazer a análise apenas do RA. Havendo RA bom/ruim em área de sombra sobre o RA e havendo RA bom/ruim sob veículos, esses não são avaliados.




Figura 4.15 - Caracterização das 4 classes informacionais em destaque na imagem
Fonte: Imagem QuickBird 2 pancromática com 0,6m de resolução espacial

Optou-se por uma classificação *pixel a pixel* (fase de descrição dos objetos) e utilizou-se a imagem multiespectral composta de quatro bandas (nas regiões do espectro eletromagnético correspondente ao azul, verde, vermelho e infravermelho próximo) como variáveis discriminantes (fase de extração de características). Foram selecionadas amostras independentes, sendo divididas em amostras de treinamento e amostras de teste, respectivamente. Nas amostras de treinamento foram extraídas as seguintes quantidades para cada classe: Classe 1 - 200 amostras de “RA bom”; Classe 2 - 140 amostras de “RA com defeito”; Classe 3 - 80 amostras de “sombra no RA”; Classe 4 - 80 amostras de “veículos sobre o RA”. Já para as amostras de teste selecionou-se

exatamente a metade, ou seja: Classe 1 - 100 amostras de “RA bom”; Classe 2 - 70 amostras de “RA ruim”; Classe 3 - 40 amostras de “sombra no RA”; Classe 4 - 40 amostras de “veículos sobre o RA”. Estas quatro classes estão apresentadas na Figura 4.15, na qual os pixels de cada classe foram extraídos do interior das elipses, tanto para a fase de treinamento quanto para a fase de teste. Os padrões foram verificados diretamente no campo.

No processo de seleção desses padrões (valores dos níveis de cinza), colocou-se lado a lado a imagem pancromática e a imagem multiespectral. Esse procedimento foi adotado para facilitar a identificação de *pixels* pertencentes às classes de estudo, devido a imagem pancromática ter uma resolução espacial 4 vezes melhor que a da imagem multiespectral - Figura 4.16.




Figura 4.16 - Imagem pancromática (esquerda) e imagem multiespectral (direita) de uma mesma cena, mostrando a diferença na resolução espacial

O *software* utilizado para a extração dos valores dos *pixels* foi o *Erdas Image 8.5*, da ERDAS Inc.

Com os dados extraídos, passou-se a fase de classificação propriamente dita, utilizando-se inicialmente o algoritmo MaxVer.

Posteriormente, foi realizada uma classificação supervisionada usando uma RNA. O *software* utilizado foi o *Java Neural Network Simulator 1.1* (JavaNNS), desenvolvido pelo *Institute for Parallel and Distributed High Performance System* das Universidades de *Stuttgart* e *Tubingen*, disponível no portal http://www.ra.cs.unituebingen.de/software/JavaNNS/welcome_e.html.

Normalmente a modelagem de RNA exige as seguintes etapas: a) preparação dos dados, na qual os dados foram re-escalados no intervalo de 0 (zero) a 1 (um), para evitar saturação na rede no início do treinamento; b) definição da topologia interna da rede a qual seguiu o procedimento descrito por Hirose *et al.* (1991); c) escolha dos parâmetros da rede: os pesos iniciais foram gerados aleatoriamente variando de -0,3 a 0,3 (VIEIRA, 2000), utilizou-se função de ativação logística e taxa de aprendizagem (η) 0,2 e *momentum* (m) com valor fixo de 0,9; d) uso das funções de aprendizagem *backpropagation* e *backpropagation* com *momentum*.

Após o treinamento, as amostras de teste, coletadas independentemente, foram utilizadas para a validação dos resultados, nas quais foram geradas as matrizes de erro e índices derivados para análises estatísticas.

4.6.1.4. RESULTADOS E DISCUSSÕES

Os resultados da classificação usando o algoritmo da Máxima Verossimilhança (MaxVer) com as 250 amostras independentes de teste estão apresentados na Tabela 4.5.

Tabela 4.5 - Matriz de erros com os resultados do classificador MaxVer

MATRIZ DE ERROS						
Classes	1	2	3	4	Total	E.C.(%)
1	66	13	1	0	80	17,5
2	29	56	2	1	88	36,5
3	5	1	36	0	42	14,3
4	0	0	1	39	40	2,5
Total	100	70	40	40	250	
E.O.(%)	34	20	10	2,3		

Onde: Classe 1 - RA bom; Classe 2 - RA com defeito; Classe 3 - sombra no RA; Classe 4 - veículos sobre o RA

O erro de comissão (EC), ou seja, erro devido a *pixels* que são erroneamente incluídos em uma dada classe quando deveriam ser assinalados à classe correta, teve o maior valor na Classe 2 (RA com defeito), seguido da

Classe 1 (RA bom), após a Classe 3 (sombra no RA) e, finalmente, a Classe 4 (veículos sobre o RA), que praticamente não teve *pixel* incluído em outra classe.

Já quanto ao erro de omissão (EO), ou seja, erro devido a *pixels* classificados omitidos de sua correta classe e assinalados a outra classe, teve o maior valor na Classe 1, seguido pela Classe 2, depois a Classe 3 e, finalmente, a Classe 4, que praticamente não teve *pixel* assinalado em outra classe.

O valor obtido de exatidão global (EG) foi igual a 78,8%, que é um valor relativamente alto para imagens de altíssima resolução, considerando as classes e as variáveis discriminantes em estudo. Acredita-se que esse bom resultado foi obtido em parte porque as amostras selecionadas possivelmente tinham uma distribuição normal para essas classes, que é uma das suposições assumidas pelo classificador MaxVer.

O valor do índice Kappa foi 0,706 e a sua variância igual a 0,001353, que representam uma ponderação entre as concordâncias e discrepâncias dos dados de referência e os dados classificados pelo MaxVer. Com o índice Kappa e sua variância é possível aplicar o teste estatístico Z, que para essa matriz obteve o valor de 19,190, que é maior que o valor tabelado de 1,96, e, portanto, significativo para 95% dos níveis de confiança, sendo melhor que uma classificação aleatória. Embora a variância do índice Kappa tenha sido um pouco alta, os outros resultados estatísticos foram bastante animadores, mesmo no caso de RA ruim, em que 63,5% das amostras foram classificadas corretamente.

Em relação à utilização das redes neurais artificiais, após uma bateria de testes os resultados não foram animadores. A rede não convergia para os dados de treinamento amostrados. Na Figura 4.17 é apresentado o gráfico típico do erro médio quadrático (EMQ) que foi encontrado ao longo de todas as tentativas, evidentemente com pequenas variações.




Figura 4.17 - Gráfico do EMQ, denotando a não convergência da RNA

Segundo Hara *et al.* (1994) uma RNA está bem treinada quando o desvio padrão do erro permanece constante, no mínimo, três casas decimais. Esse parâmetro não foi atingido em nenhuma das 27 topologias testadas.

4.6.1.5. CONCLUSÕES

Esse experimento teve como objetivo analisar a possibilidade de se fazer a detecção dos defeitos superficiais de pavimentos asfálticos com o uso do sensoriamento remoto através de imagens orbitais de altíssima resolução, utilizando técnicas estatísticas de reconhecimento de padrões e redes neurais artificiais (RNA). Baseado nos testes desenvolvidos apresenta-se as seguintes conclusões.

Quanto à análise estatística (algoritmo da Máxima Verossimilhança): a) a classificação obteve excelentes índices de exatidão global e Kappa, e o teste estatístico Z comprovou que a classificação foi significativamente melhor do que uma classificação aleatória; b) percebe-se que o algoritmo teve dificuldade em separar a classe 2 (RA ruim) da classe 1 (RA bom), mas mesmo assim o resultado foi surpreendentemente aceitável.

Quanto à Rede Neural Artificial: a) a rede não convergiu para os dados de treinamento apresentados; b) para a resolução espacial do sensor utilizado, a resposta espectral das classes RA boa e RA ruim são muito semelhantes; c) acredita-se que a RNA não convergiu porque as Classe 1 (RA bom) e Classe 2

(RA ruim) tinham valores espectrais muito parecidos. Dessa forma, a RNA não conseguia distinguir bem essas classes, causando grande confusão.

Por tratar-se de um único experimento e com resultados, de certa forma, até surpreendentemente bons na análise estatística (algoritmo da Máxima Verossimilhança), talvez seja prudente realizar outros, com a mesma metodologia adotada, para se ter comparações.

4.6.2. SEGUNDO EXPERIMENTO

4.6.2.1. CONTEXTUALIZAÇÃO E OBJETIVO

Este experimento tem por objetivo analisar a possibilidade de se fazer a detecção de defeitos superficiais nos pavimentos asfálticos, com o uso do sensoriamento remoto através de imagens terrestres multiespectral.

O uso de imagens terrestres para a detecção de defeitos superficiais em pavimentos, de forma a minimizar custos e tempos de levantamentos no campo, assim como melhorar a repetitividade dos dados levantados, tem sido razoavelmente bem explorado na literatura internacional. Trabalhos como os relacionados no Capítulo 2, seção 2.3.3, apontam várias soluções para esse problema, mas o uso de imagens terrestres multiespectrais praticamente não tem sido utilizado neste contexto. Já na literatura nacional, não se tem registro de trabalhos nessa área, com o uso de imagens multiespectrais.

Para a classificação das imagens foi utilizado como regra de decisão os classificadores MaxVer e redes neurais artificiais (RNA) no reconhecimento de padrões.

4.6.2.2. METODOLOGIA DO TRABALHO

(i) Geração das imagens sintéticas

Para desenvolver esse experimento, optou-se em fazê-lo utilizando imagens sintéticas, uma vez que não se conseguiu adquirir uma câmera terrestre multiespectral.

Imagens sintéticas são imagens construídas com alguma(s) característica(s) que se queira dar destaque. Aqui, o que se coloca em evidência são os padrões de RA analisados nesse experimento, que são: a) RA novo e em bom estado de conservação (padrão 1); b) RA velho e em bom estado de conservação (padrão 2); c) RA com defeito - baixo grau de deterioração (padrão 3); d) RA com defeito - alto grau de deterioração (padrão 4). A Figura 4.18 apresenta imagens dos 4 padrões analisados. Em (a) tem-se o RA bom e novo, em (b) o RA bom e velho, em (c) o RA com baixo grau de deterioração e em (d) o RA com alto grau de deterioração.



Figura 4.18 - Padrões de RA analisados

As características espectrais dos padrões analisados foram obtidas através do experimento com o espectrorradiômetro, descrito no Capítulo 3.

Baseado nos estudos do Capítulo 3, a primeira providência foi estabelecer as quatro bandas espectrais utilizadas na geração da imagem sintética. Essas quatro bandas correspondem àquelas que melhor discriminam as classes de RA, quais sejam: a) banda 1 - 400 a 500 nm; b) banda 2 - 500 a 600 nm; c) banda 3 - 600 a 700 nm; d) banda 4 - de 700 a 1000 nm.

Em seguida, com os dados espectrais dos 16 grupos de amostras: padrão 1 com 4 bandas, padrão 2 com 4 bandas, ..., obteve-se a média e o desvio padrão de cada grupo.

No *software* MatLab, através da função “normrnd” geraram-se imagens de 1024 x 768 *pixels*, de cada padrão e em cada banda, totalizando 16 imagens. A função “normrnd” tem como parâmetros a média e o desvio padrão dos dados e a dimensão da imagem que se vai gerar, obtendo-se imagens cujos *pixels* foram gerados segundo a distribuição normal e espalhados aleatoriamente na imagem.

A etapa seguinte foi realizar um re-escalamento dos valores dos *pixels*

das imagens geradas para ficar dentro do intervalo máximo e mínimo dos dados originais. A Figura 4.19 apresenta o procedimento do re-escalamento dos valores dos *pixels*.




Figura 4.19 - Representação do re-escalamento dos valores dos *pixels*

Considerando os valores MAX e MIN dos dados originais, ou seja, dados gerados pelas curvas de reflectância e os valores min e max dos dados gerados pela função *normrnd* do *software* MatLab, o valor x_s fica re-escalado para X_s , usando a Equação 4.7, que é similar à Equação 4.6, bastando fazer $\max = 1$ e $\min = -1$.

$$X_s = \frac{(x_s - \min)(\max - \min)}{(\text{MAX} - \text{MIN})} + \text{min} \quad (4.7)$$

Agora, as dezesseis imagens têm pixels que são os valores de reflectância, distribuídos aleatoriamente, variando, para cada banda analisada, entre o valor máximo e mínimo originais.

A Figura 4.20 apresenta uma imagem obtida no processo de geração e re-escalamento. Essa imagem possui valores de reflectância de um padrão, em uma banda definida, tamanho 1024x768 *pixels*.

O passo seguinte foi criar a imagem sintética para ser classificada. Essa imagem tem os quatro padrões considerados e as quatro bandas analisadas, totalizando quatro imagens. Para essa montagem utilizou-se os *softwares* AutoCAD 2006, da empresa Autodesk, o PhotoPaint 12, da empresa Corel Corporation e o ImageJ 1.40g, do National Institutes of Healths.




Figura 4.20 - Exemplo de uma imagem gerada e re-escalada

Optou-se por formas geométricas para representar os padrões de RA com baixa deterioração e alta deterioração, sendo distribuídos ao longo da imagem; os padrões RA novo e bom e RA velho e bom ficaram como “fundo”. O padrão RA novo e bom na metade superior da imagem e o padrão RA velho e bom na metade inferior da imagem, conforme Figura 4.21.




Figura 4.21 - Imagem sintética gerada em uma banda e com os padrões analisados

Para fazer a classificação necessita-se, ainda, de ter uma imagem de referência⁵. A Figura 4.22 apresenta a imagem de referência utilizada.



Figura 4.22 - Imagem de referência utilizada

⁵ *Imagem de referência* é um mapa de classes com as amostras de treinamento previamente definidas.

Tendo-se a imagem sintética, gerada nas 4 bandas consideradas e a imagem de referência, o passo seguinte foi realizar a classificação da imagem. Para tanto, utilizou-se os classificadores MaxVer e RNA, conforme descritos a seguir.

(ii) Classificação da imagem utilizando o classificador MaxVer

O *software* utilizado para fazer a classificação da imagem sintética e posterior avaliação da imagem classificada, utilizando o classificador MaxVer, foi o *Idrisi Andes* da *Clark University*.

Os resultados da classificação são discutidos na seção 4.6.2.3 e detalhes dos comandos utilizados na classificação e avaliação da imagem classificada são mostrados no Apêndice A desta tese.

A seguir, fez-se a classificação da imagem sintética através de uma RNA.

(iii) Classificação da imagem utilizando o classificador RNA

O *software* utilizado para fazer a classificação da imagem sintética, utilizando o classificador RNA, foi também o *Idrisi Andes*.

Os resultados dessa classificação também são discutidos na seção 4.6.2.3 e detalhes dos comandos utilizados na classificação e avaliação da imagem classificada são mostrados no Apêndice A desta tese.

4.6.2.3. RESULTADOS E DISCUSSÕES

Os resultados da classificação usando o algoritmo MaxVer e a imagem de referência para a validação da imagem estão apresentados na Tabela 4.6.

O valor obtido de exatidão global foi igual a 99,37%, designando a imagem temática obtida na classificação como de “boa qualidade”.

O valor do índice Kappa foi 0,9902, o qual, de acordo com a Tabela 4.3, indica como “excelente” o desempenho da classificação.

Tabela 4.6 - Matriz de erros com os resultados do classificador MaxVer

MATRIZ DE ERROS							
Classe	1	2	3	4	Total	Correto(%)	E.C.(%)
1	326327	0	0	466	326793	99,86	0,14
2	0	60791	2446	0	63237	96,13	3,87
3	0	3	66731	2004	68738	97,08	2,92
4	0	8	0	327656	327664	100,00	0
Total	326327	60802	69177	330126	786432		
E.O.(%)	0	0,02	6,54	0,75			

Onde: Classe 1 - RA novo e bom; Classe 2 - RA velho e bom; Classe 3 - RA com baixa deterioração; Classe 4 - RA com alta deterioração.

O erro de comissão, ou seja, erro devido a *pixels* que são erroneamente incluídos em uma dada classe quando deveriam ser assinalados à classe correta, teve o maior valor na Classe 2 (RA velho e bom), seguido da Classe 3 (RA com baixa deterioração), após a Classe 1 (RA novo e bom) e, finalmente, a Classe 4 (RA com alta deterioração), que não teve *pixel* incluído em outra classe.

Já quanto ao erro de omissão, ou seja, erro devido a *pixels* classificados omitidos de sua correta classe e assinalados a outra classe, teve o maior valor na Classe 3, seguido pela Classe 4, depois a Classe 3 e, finalmente, a Classe 1, que não teve *pixel* assinalado em outra classe.

Em relação à utilização das RNAs, definiram-se os seguintes parâmetros iniciais: a) 250 *pixels* por classe para o treinamento; b) 125 *pixels* por classe para teste; c) taxa de aprendizagem (h) inicial igual a 0,002; d) *momentum* (m) de 0,9; e) função de ativação sigmoideal; f) definição da topologia, com quatro neurônios na camada de entrada (correspondendo às bandas), 4 neurônios na camada de saída (correspondendo às classes) e iniciando a camada escondida com 1 neurônio, conforme relatado por Vieira (2000); g) número de ciclos inicial igual a 10.000.

A topologia que obteve o menor erro médio quadrático foi 4-5-4 e

verificou-se que o número de ciclo poderia baixar para 2.000, sem haver perda da taxa de acurácia da rede.

Os resultados da classificação estão apresentados na Tabela 4.7.

Tabela 4.7 - Matriz de erros com os resultados do classificador RNA

MATRIZ DE ERROS							
Classe	1	2	3	4	Total	Correto(%)	E.C.(%)
1	325150	0	0	1177	326327	99,64	0,36
2	0	60665	6	131	60802	99,67	0,23
3	0	2480	66693	4	69177	96,41	3,59
4	1675	43	2004	326404	330126	98,87	1,13
Total	326327	60802	69177	330126	786432		
E.O.(%)	0,51	3,99	2,93	0,40			

Onde: Classe 1 - RA novo e bom; Classe 2 - RA velho e bom; Classe 3 - RA com baixa deterioração; Classe 4 - RA com alta deterioração.

O valor obtido de exatidão global foi igual a 99,52%, designando a imagem temática obtida na classificação como de “boa qualidade”.

O valor do índice Kappa foi 0,9850 e que, de acordo com a Tabela 4.3, indica como “excelente” o desempenho da classificação.

O erro de comissão teve o maior valor na Classe 3 (RA com baixa deterioração), seguido da Classe 4 (RA com alta deterioração), após, a Classe 1 (RA novo e bom) e, finalmente, a Classe 2 (RA velho e bom).

Já quanto ao erro de omissão teve o maior valor na Classe 2, seguido pela Classe 3, depois a Classe 1 e, finalmente, a Classe 4.

4.6.2.4. CONCLUSÕES

Este experimento teve como objetivo analisar a possibilidade de se fazer a detecção dos defeitos superficiais de pavimentos asfálticos através de imagens sintéticas, utilizando técnicas estatísticas e redes neurais artificiais

(RNA) no reconhecimento de padrões. Baseado nos testes desenvolvidos apresenta-se as conclusões a seguir.

Quanto à análise estatística (algoritmo MaxVer): a) a classificação obteve excelentes índices de exatidão global e Kappa; b) o algoritmo teve maior dificuldade para separar a Classe 2 (RA velho e bom) da Classe 3 (RA com baixa deterioração).

Quanto à Rede Neural Artificial: a) a rede convergiu rapidamente para os dados de treinamento apresentados, distinguindo bem as classes; b) a classificação obteve excelentes índices de exatidão global e Kappa; c) o algoritmo teve maior dificuldade para separar a classe 3 (RA com baixa deterioração) da classe 4 (RA com alta deterioração).

4.7. RESUMO DO CAPÍTULO

Como síntese desse capítulo, abordou-se estratégias e procedimentos para o reconhecimento automático de padrões de defeitos em superfícies asfálticas.

Muito embora os resultados com o classificador MaxVer tenha sido surpreendentemente bom com o uso de imagem orbital, deve-se ter precaução por tratar-se de um único experimento. O ideal seria fazer novos experimentos com a metodologia adotada para confirmação dos resultados. A principal conclusão do experimento com imagem orbital é que a resolução espacial dessas imagens ainda não é suficiente para a aplicação específica nessa área, ou seja, detectar defeitos superficiais em pavimentos asfálticos. A expectativa é que muito em breve, com a evolução na melhoria da resolução espacial das imagens orbitais, essa possibilidade seja aplicável.

Quanto ao uso de imagens terrestres, muito embora se tenha utilizado uma imagem sintética, o segundo experimento confirmou que no momento atual esse caminho parece ser o mais promissor. Os dois algoritmos de classificação analisados, MaxVer e RNA, apresentaram excelentes resultados e, tanto um quanto o outro, podem ser indicados para a tarefa de

reconhecimento automático de padrões em defeitos superficiais de pavimentos. Fica a expectativa do uso e testes com imagens multiespectrais terrestres reais (obtenção da imagem, geração da imagem de referência e o mesmo procedimento da classificação) para a confirmação dos resultados obtidos com as imagens sintéticas.

CAPÍTULO 5

DISCRIMINAÇÃO DE DEFEITOS SUPERFICIAIS EM PAVIMENTO ASFÁLTICO ATRAVÉS DA TEXTURA

As características espectrais de imagens multiespectrais foram consideradas nesta tese como as variáveis discriminatórias no reconhecimento automático de padrões. Agora, se a imagem for monocromática, pode-se utilizar a textura para discriminar diferentes classes nessa imagem. Nesse capítulo, propõe-se utilizar a textura de uma imagem monocromática do pavimento asfáltico como variável discriminatória no procedimento de reconhecimento de padrões de defeitos em superfícies asfálticas, indicando uma metodologia para seleção das medidas texturais que maximize a discriminação entre classes.

5.1. INTRODUÇÃO

A textura é uma importante característica utilizada na interpretação visual de imagens, sendo considerada, assim como o tamanho, a cor, a tonalidade, etc, um elemento básico para discriminar objetos diferentes em uma imagem (RENNÓ, 2003).

Ao contrário da informação espectral, que descreve a variação do nível de cinza de um *pixel*, a textura contém informações sobre a distribuição espacial dos níveis de cinza de uma região e que não podem ser identificados individualmente, ou seja, textura é propriedade de uma região e não de um único ponto. Termos como suave, rugosa, fina, áspera, aveludada, são utilizados para descrever visualmente a textura (SANTOS, 2002).

Provavelmente, a característica mais relevante da textura seja sua dependência da escala da imagem. Um objeto pode apresentar certa textura, mas quando visto de outra posição no espaço, sua textura pode modificar radicalmente, por exemplo, sair de áspera para lisa. Técnicas de extração de textura são desenvolvidas na intenção de extrair informações da distribuição

espacial de uma determinada região da imagem, com o objetivo de melhorar o desempenho dos algoritmos de classificação (PAGAMISSE, 2003).

A textura possui um conceito intuitivo, de difícil definição, porém podendo ser descrita por suas propriedades, pois se caracteriza pela repetição de um padrão sobre uma região, o qual pode ser exato ou com pequenas variações (PAGAMISSE, 2003).

A textura é um excelente descritor regional, útil nos processos de reconhecimento, descrição e classificação de imagens, sendo que sua extração automática em uma imagem é complexa e exige alto nível de sofisticação computacional (SANTOS, 2008).

Segundo Haralick *et al.* (1973), a textura constitui uma característica relacionada diretamente com as propriedades físicas do objeto, contendo informações relevantes sobre o arranjo estrutural superficial.

Sklansky (1978) afirma que “Uma região em uma imagem apresenta uma textura única se um conjunto de estatísticas ou outra propriedade local da imagem for constante, de variação suave ou aparentemente periódica”.

Visualmente, a análise da textura em uma imagem não é um processo complexo, pois o olho humano é o instrumento mais eficiente para discriminar texturas. Tratando-se, agora, de um procedimento computacional, essa análise torna-se razoavelmente complexa.

A imagem do pavimento asfáltico apresenta texturas diferenciadas e, analisando um revestimento novo e sem defeito, basicamente as misturas asfálticas têm texturas mais lisas e os tratamentos superficiais possuem texturas mais ásperas. A explicação para esse fato é que as misturas asfálticas possuem os agregados menos expostos na superfície do revestimento, pois esses estão mais envolvidos pelo masticado asfáltico, ou seja, há um melhor entrosamento entre os agregados e o masticado asfáltico. Nos tratamentos superficiais os agregados ficam mais expostos na superfície do revestimento, denotando a superfície áspera. Observa-se na Figura 5.1 a caracterização da textura na

imagem da superfície do revestimento asfáltico, na qual em (a) tem-se a imagem de um concreto betuminoso usinado a quente (CBUQ) e em (b) tem-se a imagem de um tratamento superficial duplo (TSD).




Figura 5.1 - Exemplos de textura: (a) textura lisa (CBUQ) e (b) textura áspera (TSD)

Com o tempo e o uso, os revestimentos asfálticos começam a se modificarem. O masticado asfáltico desenvolve um processo de clareamento, devido à sua oxidação e os agregados expostos na superfície tornam-se mais arredondados, aumentando o brilho da superfície em relação à superfície do RA novo. Devido à passagem dos veículos, ocorre o emborrachamento nas trilhas de roda, formando uma faixa com brilho baixo. A textura do revestimento asfáltico deteriorado modifica-se, tornando-se, via de regra, cada vez mais áspera, ocasionada pelo aparecimento dos vários defeitos superficiais.

Antes de encerrar essa seção é fundamental um esclarecimento sobre o termo “textura do pavimento” utilizado na engenharia rodoviária. Esse termo está intimamente ligado à aderência pneu-pavimento, sendo um dos fatores que contribui para a segurança dos veículos.

Segundo Spetch *et al.* (2006), são 3 os tipos de textura que o revestimento asfáltico apresenta: a) micro-textura; b) macro-textura; c) mega-textura.

A *micro-textura* está relacionada à superfície do agregado mineral, podendo ser áspera ou polida. É de importância fundamental para romper o filme de água quando do contato pneu-asfalto.

A *macro-textura* são as asperezas do revestimento asfáltico causado pelas faces do agregado. É influenciada pela distribuição granulométrica do

agregado, a dosagem da mistura asfáltica e o processo construtivo do revestimento. Está diretamente relacionada aos seguintes fatores: a hidroplanagem, formação de *spray*, aumento do consumo de combustível, ao atrito em alta velocidade, excesso no nível de ruído ao rolamento e desgaste dos pneus.

Na Figura 5.2, apresenta-se a diferenciação entre micro-textura e macro-textura, onde a macro-textura representa a altura média (mm) do “relevo” da superfície e a micro-textura está associada à superfície do agregado (lisa ou áspera).




Figura 5.2 - Micro-textura e macro-textura em pavimento
Fonte: adaptado de Rodrigues Filho (2006)

A *mega-textura* são irregularidades superficiais do revestimento asfáltico, podendo produzir vibrações consideráveis, afetar o atrito pneu-pavimento, afetar o conforto ao rolamento e o custo operacional dos veículos.

O conceito de textura em imagem, abordado nesta tese, diferencia do conceito utilizado na engenharia rodoviária. Aqui, textura será analisada como lisa ou áspera, sendo utilizada como possível indicadora de defeitos superficiais no pavimento.

Nas próximas seções (5.2 a 5.5) faz-se uma abordagem sobre métodos de extração de textura. Na seção 5.6 desenvolveram-se experimentos com dois diferentes métodos de extração de textura em imagens de pavimentos.

5.2. MÉTODOS PARA DISCRIMINAÇÃO DA TEXTURA

Como citado na seção 5.1, discriminar textura em imagens envolve a identificação de regiões com texturas uniformes. Inicialmente, define-se qual o método para discriminação será utilizado (apresentados nas subseções 5.2.1 a 5.2.5.) para, posteriormente, definir como a textura será quantificada (ou extraída) - apresentados na seção 5.3.

Os modelos mais usuais para discriminação de textura são divididos nas seguintes classes (PAGAMISSE, 2003): a) métodos estruturais ou geométricos; b) métodos estatísticos; c) métodos de multirresolução; d) métodos de transformadas; e) métodos baseados em modelos.

Na sequência das subseções (5.2.1 a 5.2.5) tem-se a explicação de cada método.

5.2.1. MÉTODOS ESTRUTURAIS OU GEOMÉTRICOS

Nos métodos estruturais ou geométricos a textura é caracterizada como sendo composta de primitivas bem definidas, denominadas *elementos de textura*, e que são agrupadas conforme alguma regra sintética. Os modelos estruturais permitem descrever somente texturas regulares, não sendo indicado para imagens naturais (PEDRINI e SCHWARTZ, 2008).

5.2.2. MÉTODOS ESTATÍSTICOS

Os métodos estatísticos, para obter informações texturais da imagem, baseiam-se na exploração de parâmetros estatísticos dos *pixels* de acordo com a distribuição dos níveis de cinza da imagem (por exemplo: média, variância, histograma, correlações locais dos níveis de cinza, etc).

A destacar, o método para extração de atributos de textura, que foi introduzido por Haralick *et al.* (1973), baseado em estatísticas da matriz de co-ocorrência dos níveis de cinza (GLCM). Esse procedimento não será abordado nesse trabalho.

5.2.3. MÉTODOS DE MULTIRRESOLUÇÃO

Multirresolução é entendido como o problema de representar objetos em diferentes escalas e permitir que cada um seja visualizado com o nível de detalhamento necessário. Os seres humanos, evidenciados por estudos psicofisiológicos, aplicam o processamento multiescala para reconhecer e identificar texturas mais facilmente, realizando um tipo de análise espaço-frequência (PAGAMISSE, 2003).

As transformadas *Wavelet* são utilizadas para uma análise de texturas em multirresolução, sendo discutida na seção 5.4 e utilizada nos experimentos desse capítulo.

5.2.4. MÉTODOS DAS TRANSFORMADAS

Esses métodos utilizam uma transformada¹ para representar a imagem no domínio das frequências, com características texturais mais facilmente perceptíveis e tem-se, como exemplo, a *Transformada de Fourier*. Esse procedimento não será abordado nesse trabalho.

5.2.5. MÉTODOS BASEADOS EM MODELOS

Os métodos baseados em modelos constroem um modelo estocástico ou gerador de texturas, onde os parâmetros do modelo são determinados na imagem, atuando como atributos. São exemplos de modelos usualmente utilizados: fractais, Markov, Gibbs-Markov, etc (PAGAMISSE, 2003). Esse procedimento não será abordado nesse trabalho.

Definido o método que se vai utilizar na análise de textura, a próxima etapa é caracterizar como será feita a medida da textura (quantificação) na imagem, através dos “descritores” ou “extratores”, apresentados na seção seguinte.

¹ *Transformada* é um procedimento matemático utilizada para modificar a representação dos dados originais, de modo que estes possam ser mais facilmente analisados.

5.3. QUANTIFICAÇÃO DA TEXTURA

A quantificação da textura é baseada em estatísticas de 1ª ordem, 2ª ordem e de ordem superior.

5.3.1. MEDIDA BASEADA EM ESTATÍSTICA DE 1ª ORDEM

A medida da textura, baseada em parâmetros estatísticos de primeira ordem, é caracterizada por não levar em consideração a distribuição espacial dos níveis de cinza de uma região da imagem.

Os parâmetros média, variância, correlações locais dos níveis de cinza, momentos de ordem superior (por exemplo: curtose, *skewness*) são comumente utilizados na medida da textura usando estatística de 1ª ordem (PEDRINI e SCHWARTZ, 2008).

5.3.2. MEDIDA BASEADA EM ESTATÍSTICA DE 2ª ORDEM

Neste caso, a medida da textura baseada em parâmetros estatísticos de segunda ordem, leva em consideração a distribuição espacial dos níveis de cinza de uma região da imagem.

São exemplos de medida de textura baseadas em parâmetros estatísticos de segunda ordem: função de autocorrelação espacial, métodos baseados na frequência espacial, métodos baseados na frequência de borda, parâmetros extraídos da matriz de co-ocorrência.

5.3.3. MEDIDA BASEADA EM ESTATÍSTICA DE ORDEM SUPERIOR

Aqui são utilizados modelos mais complexos, baseados em: a) códigos de comprimento (*run length codes*); b) leis da medida de energia da textura; c) fractal; d) morfologia matemática; e) Transformada Wavelet.

5.4. EXTRAÇÃO DA TEXTURA UTILIZANDO A TRANSFORMADA WAVELET

Com o advento das técnicas de processamento digital de sinais, a Transformada *Wavelet* tem sido utilizada como um bom substituto da Transformada de Fourier na análise de imagens (MISIT, 1997).

A Transformada de Fourier, ao realizar a transformação do sinal para o domínio da frequência, a informação espacial do sinal é perdida, ou seja, embora seja possível determinar todas as frequências de um sinal, não se sabe exatamente onde elas estão presentes e, normalmente, a parte mais importante de um sinal é sua característica transitória², pois em várias aplicações é necessário conhecer a frequência e a localização do sinal espacialmente (CASTAÑÓN, 2003).

Wavelets têm como grande potencial a habilidade em realizar análises locais, ou seja, é capaz de isolar e analisar em detalhes uma região bastante pequena de um sinal, sendo possível revelar aspectos dos dados onde outras técnicas de análise de sinal no domínio da frequência ficam a desejar (CASTAÑÓN, 2003).

Cuhadar *et al.* (2002) apresentaram um algoritmo baseado na Transformada *Wavelet* para fazer a segmentação³ automática dos dados de irregularidade dos pavimentos, levantamentos pelo perfilômetro a laser. O método consiste em remover pequenas ondulações na forma da onda, enquanto as informações importantes dos dados são preservadas. Com a Transformada *Wavelet* é feita a detecção de singularidades na parte suave da forma da onda e que são marcadas como “singularidades isoladas” ou como “pontos de limites”. As singularidades isoladas são eliminadas e as singularidades restantes são usadas como informações de limite para

² *Características transitórias* de um sinal são devidas às propriedades do sinal mudar com o tempo, tais como: inclinações, tendências, mudanças abruptas e inícios e términos de eventos;

³ *Segmentar* dados consiste em identificar aqueles que têm características uniformes. Segmentar imagens significa separar os objetos similares (que atenda a uma ou várias propriedades) para posterior identificação.

segmentar os dados da condição do pavimento em regiões que têm características similares. Os resultados obtidos verificam o alto desempenho da Transformada *Wavelet* para segmentação automática dos dados de irregularidade do pavimento. Porém, outros dados do pavimento, como profundidade da trilha de roda, também pode ser utilizado na segmentação (CUHADAR *et al.*, 2002).

Subirats *et al.* (2006) apresentaram uma metodologia para a automação na detecção de trincas com o uso de imagens da superfície do pavimento, que é baseado na Transformada *Wavelet* Contínua. A função *Wavelet* mãe é definida usando uma filtragem, sendo o método auto-adaptável para a textura do pavimento. No método, os valores máximos dos coeficientes *wavelets* são pesquisados e analisados sua propagação, através das diferentes escalas. Na etapa final, um pós-processamento sobre a imagem binária obtida indicará a presença ou não de trincas sobre o pavimento.

A Transformada *Wavelet* decompõe o sinal por meio de uma série de funções elementares, criadas a partir de escalas e translações sobre uma função base - Equação 5.1, na qual t é o tempo e a é o parâmetro de escala (também chamado de *dilatação*) - aumentando (se $a > 1$) ou diminuindo (se $a < 1$) a *Wavelet* formada pela função. Já b é o parâmetro de translação, indicando que a *Wavelet* foi transladada no eixo t de uma distância equivalente a b . A função $\psi_{1,0}$ ($a = 1$ e $b = 0$) é denominada *Wavelet mãe*, enquanto as outras funções $\psi_{a,b}$ são chamadas de *Wavelets filhas* (ou *família de Wavelets*). O termo $(1/\sqrt{a})$ é um fator de normalização da função *Wavelet* (PEDRINI e SCHWARTZ, 2008).

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (5.1)$$

Dentre as famílias de *Wavelets* mais conhecidas, tem-se: a) *Haar* - é a primeira e mais simples de todas; b) *Daubechies* - que são uma família de funções caracterizadas pelo seu nível de localização espacial *versus* suavidade; c) *Biortogonal* - apresenta a propriedade de fase linear, necessária

na reconstrução de sinais e imagens; d) *Coiflets* - limita os momentos de decaimento na função *Wavelet* e também na função escala, tendo como vantagem o fato dos coeficientes de aproximação poderem ser representados pelas amostras do sinal, no entanto, a ordem dos filtros torna-se elevada; e) *Symlets* - são *Wavelets* simétricas e foi proposta como uma modificação da *Wavelet Daubechies*; f) *Morlet* - não possui função escala mas é explícita; g) *Mexican Hat* - também não possui função escala, mas não é explícita; h) *Meyer* - onde a *Wavelet* e a função escala estão definidas no domínio da frequência (UFSC-CTC-INE, 2007).

5.4.1. TRANSFORMADA WAVELET CONTÍNUA E TRANSFORMADA WAVELET DISCRETA

A soma de todo tempo (dt) de um sinal $[f(t)]$ multiplicado por funções escaladas e transladadas $[\psi_{a,b}(t)]$ define a *Transformada Wavelet Contínua* (CWT). Essa transformada gera um conjunto de coeficientes $F(a,b)$ que representam o sinal na base *Wavelet mãe* ($\psi_{a,b}$), conforme Equação 5.2.

$$F(a,b) = \int f(t)\psi_{a,b}(t)dt \quad (5.2)$$

Em termos de implementação computacional, a discretização dos dados é essencial. Assim, originou-se a *Transformada Wavelet Discreta* (DWT), na qual os parâmetros a e b assumem valores discretos. Nesse caso, o espaço do sinal não é discretizado uniformemente e a escala da *Wavelet* influencia na discretização do parâmetro de translação. Portanto, para altas frequências, as *Wavelets* são transladadas por pequenos passos e para baixas frequências, a translação é feita com passos maiores.

A maneira mais comum de se calcular os coeficientes da *Transformada Wavelet Discreta* é através da aplicação na decomposição de imagens, conforme apresentado na seção 5.4.2.

5.4.2. DECOMPOSIÇÃO DE UMA IMAGEM

Wavelets aplicam técnicas de multirresolução em imagens, objetivando

alterar sua representação. A análise de multirresolução com o uso de *Wavelets* é semelhante a um banco de filtros *Quadrature Mirror Filter* (QMF), correspondendo a sucessivas passagens de filtros passa-banda, decompondo a imagem, em cada nível, em imagens de “detalhes” e “aproximação” (MALLAT, 1989; PAGAMISSE, 2003).

Os dois filtros utilizados sobre a imagem na análise de multirresolução, um passa-baixa (*L*) e o outro passa-alta (*H*), geram um nível de decomposição e produzem quatro sub-bandas (LL, HL, LH e HH), podendo esse processo ser utilizado sucessivamente nas sub-bandas LLs. As sub-bandas LL e HH mostram as frequências baixas e altas da imagem, respectivamente, em uma resolução espacial metade. As sub-bandas HL e LH denotam, respectivamente, frequências intermediárias presentes na imagem, também em uma resolução espacial metade. As sub-bandas são também denominadas sub-imagens ou subespaços. (MALLAT, 1989; PAGAMISSE, 2003).

A Figura 5.3 (a) apresenta o esquema de decomposição inicial, denominada “nível 1”, na qual se tem quatro regiões formadas com a metade da resolução espacial da imagem original: a sub-banda LL é uma “imagem de aproximação”, a sub-banda HL é uma “imagem de detalhe horizontal”, a sub-banda LH é uma “imagem de detalhe vertical” e a sub-banda HH é uma “imagem de detalhe diagonal”. A Figura 5.3 (b) apresenta o esquema de decomposição “nível 2”, na qual a sub-banda LL é decomposta em outras quatro sub-bandas com resolução espacial um quarto da imagem original.




Figura 5.3 - Análise de multirresolução
(a) decomposição “nível 1”; (b) decomposição “nível 2”

Resumindo, a Transformada *Wavelet* decompõe a imagem na qual cada

nível de decomposição apresenta os atributos visíveis em uma dada faixa de frequência. Objetos com baixas variações em intensidades (baixa frequência) são enfatizados na sub-banda LL e altas variações em intensidade (alta frequência), tais como as bordas, aparecem nas sub-bandas HL (angulação horizontal), LH (angulação vertical) e HH (angulação diagonal). As sub-bandas de alta frequência apresentam sensibilidade às texturas nas direções horizontal, vertical e diagonal e são formadas pelos *coeficientes Wavelets*. Se os coeficientes *Wavelets* têm valores próximos de zero é porque a imagem é bastante homogênea, ou seja, é uma imagem suave. Imagens com transições (mudanças bruscas de intensidade na imagem) possuem coeficientes *Wavelets* com altos valores. (MALLAT, 1989; PAGAMISSE, 2003).

A decomposição de uma imagem utilizando filtros QMF é exemplificada na Figura 5.4, correspondendo à decomposição de nível 1 da imagem Monalisa, utilizando o filtro de *Haar*, também chamado de *Transformada Wavelet de Haar*, que consiste na decomposição da imagem em duas componentes: uma da média aritmética dos pixels (representam as componentes de baixa frequência da imagem) - Equação 5.3 e outra da diferença (isolam as componentes de alta frequência da imagem) - Equação 5.4, para imagens de 8 bits (SILVA *et al.*, 2007).

$$s = (a + b) / 2 \quad (5.3)$$

$$d = (a - s) + 128 \quad (5.4)$$

Onde:

a e *b* - são duas amostras vizinhas e sucessivas

Para explicar a Figura 5.4, imagine a 1ª linha da imagem Monalisa formada por oito colunas com os seguintes níveis de cinza:

70	130	56	170	141	31	78	56
----	-----	----	-----	-----	----	----	----

Os coeficientes da média (baixa frequência) ficam com quatro colunas:

$(70+130)/2=100$	$(56+170)/2=113$	$(141+31)/2=86$	$(78+56)/2=67$
------------------	------------------	-----------------	----------------

Os coeficientes da diferença (alta frequência) ficam também com quatro colunas:

$(70-100)+128=98$	$(56-113)+128=71$	$(141-86)+128=183$	$(78-67)+128=139$
-------------------	-------------------	--------------------	-------------------

Este procedimento é utilizado para todas as linhas da imagem, resultando nessa fase, duas sub-imagens com a metade das colunas da imagem original.




Figura 5.4 - Decomposição nível 1 da imagem Monalisa
Fonte: Silva e Minetto (2005)

Usando o mesmo raciocínio, os dois filtros são passados nas colunas das sub-imagens obtidas, resultando quatro sub-imagens com a metade das linhas das sub-imagens da etapa anterior. O final da etapa dessa decomposição são quatro sub-imagens com a resolução espacial metade da imagem original, conforme aparece na Figura 5.4, que caracterizam a separação das frequências da imagem original (LL, LH, HL, HH). Cada sub-imagem é uma matriz de coeficientes, conhecidos com o nome de *coeficientes Wavelets*. Então, tem-se: uma sub-imagem com coeficientes de aproximação, que é uma versão de baixa resolução espacial da imagem original e, também, três sub-imagens que correspondem ao coeficiente de detalhes (horizontal, vertical e diagonal), denotando as alta frequências da imagem, nas três direções.

O símbolo (↓) utilizado na Figura 5.4 é denominado operador de sub-amostragem (*downsampling*), que aplicado a uma função discreta reduz o seu

número de elementos pela metade.

Após a decomposição da imagem (no nível desejado), extraem-se seus coeficientes *Wavelets* (sub-bandas de alta frequência), que serão utilizados na classificação da imagem.

O uso da Transformada *Wavelet* na discriminação de textura tem sido bastante explorado, com resultados expressivos quando comparado a outras técnicas, por exemplo, índices derivados da matriz de co-ocorrência, transformada de Fourier, etc. Por isso, o uso de decomposição de imagem por multirresolução será utilizado nos experimentos desse capítulo (seção 5.6).

5.5. DISCRIMINAÇÃO DA TEXTURA UTILIZANDO MORFOLOGIA MATEMÁTICA

Na década de 1960, Jean Serra, Georges Matheron e seus colaboradores da Escola Nacional de Minas de Paris, desenvolveram a teoria de morfologia matemática (PEDRINI e SCHWARTZ, 2008). A morfologia matemática tem sido utilizada em várias áreas do conhecimento como, por exemplo, na medicina, biologia e metalurgia, além de aplicações em análise de textura, microscopia e na automação industrial (PEDRINI e SCHWARTZ, 2008).

Leonardi e Silva (2008) utilizaram operações morfológicas com o objetivo de extrair a drenagem presente na imagem orbital de uma área teste, obtida pelo sensor TM do satélite Landsat 5. Os resultados foram promissores e evidenciaram que técnicas de morfologia matemática podem ser empregadas na área de Cartografia com vista à extração de feições, que podem ser utilizadas em processos de atualizações de produtos cartográficos (LEONARDI e SILVA, 2008).

Morfologia matemática consiste de técnicas baseadas em operações da teoria de conjuntos e utilizadas para descrever quantitativamente estruturas geométricas presentes na imagem, semelhante ao termo “morfologia” utilizado em biologia, na qual se estuda a estrutura de animais e plantas. Para tanto, utiliza ferramentas denominadas *filtros morfológicos* e cujas máscaras são conhecidas pelo nome de *elementos estruturantes*.

Elementos estruturantes são matrizes que apresentam valores 1 (um) ou 0 (zero), de sorte a representar ou não, respectivamente, pixels da imagem analisada. A Figura 5.5 apresenta dois exemplos de elementos estruturantes de dimensão 3x3, nos quais a origem do elemento estruturante é marcado com um x.



Figura 5.5 - Exemplos de elementos estruturantes

A seguir, descreve-se sobre as operações de *erosão* e *dilatação*, consideradas as operações básicas da morfologia matemática.

5.5.1. OPERAÇÃO DE DILATAÇÃO

A operação de dilatação é definida pela Equação 5.5, que consiste em obter a reflexão de B sobre a origem ($\hat{B}$), depois deslocar esta reflexão de $\underline{x}$ [$(\hat{B})_{\underline{x}}$] e sua interseção com A inclui ao menos 1 elemento diferente de zero (GONZALEZ e WOOD, 2002).

$$D(A,B) = A \oplus B = \left\{ \underline{x} \mid (\hat{B})_{\underline{x}} \cap A \neq \Phi \right\} \quad (5.5)$$

Onde:

$\oplus$ - operador dilatação

A, B - conjuntos em Z^2

$$\hat{B} = \{ \underline{x} \mid \underline{x} = -\underline{b}, \text{ para } \underline{b} \in B \}$$

Na imagem, a operação de dilatação provoca uma aumento da área analisada (expansão), além de gerar uma imagem mais clara (níveis de cinza alto). A Figura 5.6 apresenta um esquema da operação de dilatação,

mostrando a expansão da figura após a operação.




Figura 5.6 - Operação de dilatação

5.5.2. OPERAÇÃO DE EROÇÃO

A erosão de A por B , representado por $A \ominus B$, é definida pela Equação 5.6 e que consiste no conjunto de pontos x tais que B , transladado de x $[(B)_x]$, está contido em A (GONZALEZ e WOOD, 2002).

$$E(A,B) = A \ominus B = \left\{ x | (B)_x \subseteq A \right\} \quad (5.6)$$

Onde:

$\ominus$ - operador erosão

Na imagem, a operação de erosão provoca uma diminuição da área analisada, além de gerar uma imagem mais escura (níveis de cinza baixos). A Figura 5.7 apresenta um esquema da operação de erosão, mostrando a diminuição da figura após a operação.




Figura 5.7 - Operação de erosão

As operações de erosão e dilatação, usando o mesmo elemento

estruturante, podem ser encadeadas, gerando resultados interessantes (GONZALEZ e WOOD, 2002). Nas próximas seções são apresentadas duas importantes operações morfológicas obtidas por encadeamento: a abertura e o fechamento.

5.5.3. ABERTURA

A *abertura* de um conjunto A por um elemento estruturante B , expressa por $A \circ B$, é definida de acordo com a Equação 5.7 (GONZALEZ e WOOD, 2002).

$$A \circ B = (A \ominus B) \oplus B \quad (5.7)$$

Onde:

$\circ$ - operador abertura

A, B - conjuntos em Z^2

Pela análise da Equação 5.7 observa-se que a *abertura* de A por B é simplesmente a erosão de A por B seguida de uma dilatação do resultado por B .

Em geral, a abertura suaviza o contorno da imagem, quebra istmos estreitos e elimina proeminências delgadas (MARQUES FILHO e VIEIRA NETO, 1999).

5.5.4. FECHAMENTO

O *fechamento* de um conjunto A por um elemento estruturante B , expresso por $A \bullet B$, é definido de acordo com a Equação 5.8 (GONZALEZ e WOOD, 2002).

$$A \bullet B = (A \oplus B) \ominus B \quad (5.8)$$

Onde:

$\bullet$ - operador fechamento

A, B - conjuntos em Z^2

Pela análise da Equação 5.8 observa-se que o *fechamento* de A por B é simplesmente a dilatação de A por B seguida de uma erosão do resultado por B .

Em geral, o fechamento funde pequenas quebras e alarga golfos estreitos, elimina pequenos orifícios e preenche *gaps* no contorno (MARQUES FILHO e VIEIRA NETO, 1999).

5.5.5. OPERADORES MORFOLÓGICOS EM IMAGENS BINÁRIAS

Em imagens binárias, a morfologia matemática é utilizada para extrair características da imagem que sejam úteis na representação e descrição de formas, tais como: extração de bordas, extração de componentes conectados, esqueletização de regiões, etc (GONZALEZ e WOOD, 2002). As subseções 5.5.5.1 a 5.5.5.3 abordam esses algoritmos.

5.5.5.1. EXTRAÇÃO DE BORDAS

A borda de um conjunto A , expressa por $E(A)$, pode ser obtida pela diferença A pela erosão de A por B , conforme a Equação 5.9, denominada *gradiente interno* (GONZALEZ e WOOD, 2002).

$$E(A) = A - (A \ominus B) \quad (5.9)$$

O conjunto B é um elemento estruturante adequado e, aponta-se dois exemplos: um com conectividade 8 - Figura 5.5 (figura da esquerda), e outro com conectividade 4 - Figura 5.5 (figura da direita).

Pode-se utilizar também o operador “dilatação” na extração de bordas, conforme Equação 5.10, denominada *gradiente externo*, que é diferença entre a dilatação de A por B por A (GONZALEZ e WOOD, 2002).

$$E(A) = (A \oplus B) - A \quad (5.10)$$

Como mais uma opção, tem-se o *gradiente morfológico*, Equação 5.11,

que é a soma do gradiente externo e gradiente interno (GONZALEZ e WOOD, 2002).

$$E(A) = (A \oplus B) - A(\ominus B) \quad (5.11)$$

5.5.5.2. EXTRAÇÃO DE COMPONENTES CONECTADOS

Seja Y um componente conectado contido em um conjunto A . Supondo que um ponto p de Y é conhecido. A extração de componentes conectados pode ser realizada por meio de um processo iterativo, dado pela Equação 5.12 (GONZALEZ e WOOD, 2002).

$$X_k = (X_{k-1} \oplus B) \cap A \quad k = 1, 2, 3, \dots \quad (5.12)$$

Onde:

$X_0 = p$ e B é um elemento estruturante adequado

O algoritmo converge quando $X_k = X_{k-1}$ e o resultado é o conjunto dos pontos conectados.

5.5.5.3. ESQUELETIZAÇÃO DE REGIÕES

Esqueletização de regiões (ou objetos) é uma importante representação utilizada para o reconhecimento e análise de formas. Segundo Gonzalez e Wood (2002), o esqueleto de uma região A pode ser calculado iterativamente e expresso em termos de erosão e abertura, isto é, sendo $S(A)$ o esqueleto de A , tem-se (Equação 5.13):

$$S(A) = \bigcup_{k=0}^k S_k(A) \quad (5.13)$$

Com:

$$S_k(A) = \bigcup_{k=0}^K \{(A \ominus k B) - [(A \ominus k B) \circ B]\} \quad (5.14)$$

Onde:

$(A \ominus k B)$ - indica k erosões sucessivas de A

K - último passo iterativo antes de A resultar, por erosão, em um conjunto vazio

5.5.6. OPERADORES MORFOLÓGICOS EM IMAGENS MONOCROMÁTICAS

Nas operações morfológicas em imagens em tons de cinza, o elemento estruturante pode assumir níveis de cinza de acordo com a resolução radiométrica da imagem e as operações de abertura e fechamento utilizam as mesmas expressões daquelas definidas para imagens binárias - Equações 5.6 e 5.7 (GONZALEZ e WOOD, 2002).

No caso de imagens em tons de cinza, a *abertura* pode ser vista como um processo de suavização da imagem, eliminando pequenos detalhes. Já o *fechamento* remove detalhes que são maiores que o elemento estruturante. Como aplicações de interesse, utilizando a morfologia matemática em imagens em tons de cinza, têm-se o realce de contraste, atenuação de ruídos na imagem e a granulometria (PEDRINI e SCHWARTZ, 2008).

A morfologia matemática tem sido utilizada com frequência para extrair textura. Por isso, técnicas utilizando morfologia matemática para extração de textura de imagens serão utilizadas na seção 5.6.

5.6. MATERIAIS E MÉTODOS

Nesta seção pretende-se apresentar dois experimentos que foram desenvolvidos com o objetivo de identificar defeitos superficiais nos pavimentos asfálticos, através de análise da textura de imagens terrestres monocromáticas (em tons de cinza), indicando uma metodologia que maximize a discriminação entre as duas classes analisadas: pavimento com defeito e pavimento sem defeito.

5.6.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

As imagens terrestres utilizadas nos experimentos desse capítulo foram obtidas em duas áreas: a) estacionamento do INPE - área descrita na subseção 3.3.1; b) BR-120, trecho marcado na Figura 4.15 como “Trecho 2 - RA com defeito”.

5.6.2. MATERIAL

Utilizou-se uma câmera digital, marca Sony, modelo DSC-H9 - Figura 5.8, considerada uma câmera semi-profissional. As imagens adquiridas por essa câmera são coloridas ou monocromáticas, ambas na faixa do visível, e no padrão jpeg.



Figura 5.8 - Câmera Sony, DSC-H9

No processamento das imagens utilizaram-se os *softwares*: a) MatLab, da empresa MathWorks, Inc. Natick; b) ImageJ, do National Institutes of Health; c) o *Java Neural Network Simulator 1.1 (JavaNNS)*, do *Institute for Parallel and Distributed High Performance System* das Universidades de *Stuttgart* e *Tubingen*; d) o *software FUNCPOW*, desenvolvido por Vieira (2000).

5.6.3. OBTENÇÃO DOS DADOS DE CAMPO

As imagens foram obtidas em tons de cinza, na resolução 640 x 480 *pixels* e com boa iluminação natural, evitando-se que houvesse sombra sobre os alvos. Posteriormente, fez-se uma análise visual para verificar a qualidade da imagem. Havendo qualquer problema na imagem, tais como, foco ruim, má iluminação, etc, a imagem era descartada.

Após a análise das imagens obtidas nas duas áreas, optou-se em aplicar os experimentos em 6 imagens, que apresentavam características

(defeitos mais comuns) para uma boa análise, sendo 2 imagens do estacionamento do INPE e 4 imagens da BR-120. As imagens da BR-120 ficaram assim caracterizadas: a) imagem 1 - trinca longitudinal; b) imagem 2 - trinca couro de jacaré; c) imagem 3 - buraco; d) imagem 4 - remendo. As imagens do estacionamento do INPE foram designadas: a) imagem 5 - trinca longitudinal; b) imagem 6 - trinca/buraco.

A Figura 5.9 apresenta as 6 imagens utilizadas nos experimentos desse capítulo.






NOME	LOCAL	DESCRIÇÃO	IMAGEM
Imagem 1	BR-120	Trinca longitudinal	
Imagem 2	BR-120	Trinca couro de jacaré	
Imagem 3	BR-120	Buraco	
Imagem 4	BR-120	Remendo	
Imagem 5	Estacionamento do INPE	Trinca longitudinal	
Imagem 6	Estacionamento do INPE	Trinca longitudinal e buraco	

Figura 5.9 - Imagens utilizadas nos experimentos

5.6.4. METODOLOGIA DOS TRABALHOS

Foram desenvolvidos dois experimentos, ambos com o objetivo de discriminar os defeitos na imagem através da análise de textura, usando a mesma base de dados, obtida conforme a seção 5.6.3. No primeiro experimento, utilizou-se a Transformada *Wavelet* e no segundo experimento, a morfologia matemática. Os experimentos são descritos nas subseções seguintes.

5.6.4.1. EXPERIMENTO 1 - USO DA TRANSFORMADA WAVELET

As classes informacionais analisadas na imagem do pavimento foram: a) RA sem defeito; b) RA com defeito.

A metodologia para a extração de texturas com a finalidade de caracterizar as classes consideradas consistiu em analisar a imagem por blocos (pedaços da imagem) ao invés de fazer a análise global da imagem. Essa técnica permite fazer uma exploração mais criteriosa da imagem, obtendo-se melhores resultados na classificação. Pensou-se em analisar blocos 4x4, 8x8 e 16x16 *pixels* para verificar a influência do tamanho do bloco na análise.

Resumidamente, em cada bloco da imagem aplicou-se a técnica de multirresolução pela Transformada *Wavelet*. Usou-se um único nível de decomposição e a *Wavelet Daubechies-4*, obtendo-se os coeficientes *Wavelets* nas 3 sub-bandas de alta frequência (horizontal, vertical e diagonal). Sobre os coeficientes *Wavelets* de cada sub-banda aplicou-se um único extrator e sobre o bloco original aplicou-se, também, um único extrator, que comporão o vetor de características da imagem. Após a obtenção dos vetores de características de todos os blocos da imagem fez-se uma classificação quantitativa, utilizando o algoritmo MaxVer, RNA e limiarização.

A Transformada *Wavelet Daubechies-4* foi escolhida porque fornece bons resultados no processamento de imagens (CASTAÑÓN, 2003).

O extrator dos coeficientes *Wavelets* utilizado, denominado “ICW” foi obtido experimentalmente para essa análise e se mostrou bastante sensível para discriminar as duas classes da imagem, sendo definido conforme a Equação 5.15.

$$ICW = \frac{1}{n} \sqrt{\sum_{i=1}^n \sum_{j=1}^n a_{ij}^2} \quad (5.15)$$

Onde:

a_{ij} - elemento da matriz dos coeficientes *Wavelets*

n - ordem da matriz dos coeficientes *Wavelets*

A Figura 5.10 apresenta a sequência do método. Na Etapa 1 faz-se um particionamento da imagem em blocos quadrados ($n \times n$), no qual n é um múltiplo inteiro das dimensões da imagem. Esses blocos são tratados como “regiões de textura” e sobre cada um deles é que se desenvolve a discriminação das texturas (Etapa 2). Na Etapa 3, regras de decisão são utilizadas para classificar cada bloco como “com defeito” ou “sem defeito”, obtendo-se, assim, uma imagem classificada.




Figura 5.10 - Etapas da metodologia utilizando multirresolução

(i) Etapa 1 - Determinação dos coeficientes Wavelets

Para atender essa etapa desenvolveu-se uma rotina no *software* MatLab (veja Apêndice B). A imagem é lida e particionada em blocos quadrados, cujas dimensões são definidas pelo usuário. Utilizaram-se blocos de dimensão 4x4,

8x8 e 16x16 *pixels* para a análise das imagens.

Em cada bloco extraído da imagem usou-se a Transformada *Wavelet Daubechies-4* com um nível de decomposição. Obtiveram-se as 3 sub-bandas de alta frequência, conforme apresentado na Figura 5.11. Cada uma dessas sub-bandas contém os coeficientes *Wavelets* segundo direções pré-definidas: horizontal (sub-banda 1), vertical (sub-banda 2) e diagonal (sub-banda 3).




Figura 5.11 - Determinação dos coeficientes *Wavelets* por bloco

(ii) Etapa 2 - Obtenção do vetor de características

Para essa etapa, utilizou-se a rotina desenvolvida no *software* MatLab (Apêndice B). Utilizaram-se os extratores “ICW”, Equação 5.15, sobre os coeficientes *Wavelets* nas sub-bandas, obtendo-se um valor para cada sub-banda, totalizando três. Após, selecionou-se o maior dos três valores, como valor característico das três sub-bandas. O outro valor característico foi obtido através da média do brilho do bloco analisado.

O vetor de características de cada bloco foi formado pela composição dos dois extratores (ICW e média do brilho), conforme apresenta a Figura 5.12.




Figura 5.12 - Vetor de características

O elemento E1 representa o maior valor do ICW das 3 sub-bandas de

alta frequência e o elemento E2 representa o valor médio do brilho do bloco. A escolha dos extratores foi obtida através de vários testes com grupos de outros extratores, tais como: média, desvio padrão, etc, nos quais os melhores resultados de uma análise estatística foram obtidos com esse conjunto de extratores.

(iii) Etapa 3 - Classificação da imagem

Com os vetores de características extraídos da imagem passou-se a fase de classificação propriamente dita, utilizando-se inicialmente o algoritmo MaxVer. Em seguida, foi realizada uma classificação supervisionada usando uma RNA. Finalmente, a imagem foi classificada por limiarização.

Tanto para a classificação MaxVer quanto para a RNA foram selecionadas amostras independentes, divididas em amostras de treinamento e amostras de teste, respectivamente. Nas amostras de treinamento foram extraídas as seguintes quantidades para cada classe: Classe 1 - 60 amostras (blocos) de “RA sem defeito”; Classe 2 - 60 amostras de “RA com defeito”. Já para as amostras de teste selecionou-se exatamente a metade, ou seja: Classe 1 - 30 amostras de “RA sem defeito”; Classe 2 - 30 amostras de “RA com defeito”.

Usou-se a rotina desenvolvida no *software* MatLab, que facilita a extração das amostras independentes (blocos) e a determinação dos vetores de características respectivos, por classe considerada (Apêndice B).

Para a modelagem da RNA, inicialmente, re-escalou-se os dados entre 0 e 1, para evitar saturação na rede no início do treinamento. A definição da topologia interna da rede seguiu o procedimento descrito por Hirose *et al.* (1991). Os outros parâmetros da rede ficaram assim definidos: os pesos iniciais foram gerados aleatoriamente variando de -0,3 a 0,3; utilizou-se a função de ativação logística e taxa de aprendizagem 0,2 e *momentum* com valor fixo de 0,9; uso das funções de aprendizagem *Backpropagation* e *Backpropagation com Momentum*.

Para a classificação por limiarização, utilizou-se um limiar global para cada característica. Esses dois limiares, um para o extrator ICW e outro para o brilho, foram definidos experimentalmente, pegando-se uma amostra representativa das classes consideradas, conforme apresentada na Figura 5.13, na qual em (a) tem-se a imagem original (640x480 pixels) e em (b) tem-se a amostra da imagem original (100x80 pixels).




Figura 5.13 - Extração de amostra da imagem para determinação dos limiares globais
(a) - imagem original; (b) - amostra da imagem original

Com as características calculadas para a amostra, analisou-se no *software* EXCEL os dados para a determinação dos limiares adotados, conforme Tabela 5.1.

Tabela 5.1 - Exemplo de características da amostra da imagem
(a) - valores máximos dos ICW das sub-bandas dos bloco;
(b) - média dos brilhos dos blocos

3.0393	3.6746	3.1462	2.4414	2.539	3.7356	3.2474	1.079	(a)
2.0879	4.8504	8.6941	9.8247	4.7763	3.0482	4.8487	2.0031	
5.515	5.7649	5.2324	7.4583	3.5024	9.3293	6.5794	4.3745	
17.02	4.9674	4.0483	4.8456	5.2827	8.9224	4.9843	4.4915	
4.1967	12.054	7.9852	5.9054	12.254	12.415	11.456	6.4683	
5.7748	3.4052	3.1354	6.6482	3.231	6.1391	6.5505	5.0416	
2.7418	4.0585	4.2653	4.276	2.5993	2.3164	1.677	1.4668	
3.8052	4.3718	4.6637	4.2994	1.4641	2.491	1.9419	2.9832	
138.69	136.06	137.81	138.5	134.19	126.88	134.06	131.56	(b)
139.06	136	120.06	115.75	105.63	107.69	125.5	133.88	
129.44	129.31	94.75	94.625	88.438	94.063	98.313	99.25	
98.625	121.38	115.38	112.44	100.88	114.06	124.5	129.56	
119.44	98.438	82.375	84.188	77.813	98.188	95.938	84.25	
136.44	138.19	139.38	137.69	129.5	143.75	148.63	139.44	
139.19	146	135.5	138.06	133.06	141.69	141.31	142.56	
140.81	138.69	145.94	140.56	136.06	145.63	138.88	139.44	
135	138.06	136.31	134.94	127.38	129.56	130.88	127.94	

Essa tabela apresenta apenas um pedaço do arquivo, para efeito de explicação. Em (a) tem-se os valores máximos do ICW e em (b) as médias dos brilhos de cada bloco. O par de elementos que compõem o vetor de

característica de cada bloco da amostra da imagem analisada é formado pela posição do elemento em (a) e o seu corresponde em (b). Observou-se na maioria dos pares de valores que a um alto valor do ICW, correspondia um valor baixo do brilho (conforme assinalado em amarelo).

Assim, para cada imagem a ser classificada, o valor dos limiares foram adotados em função da análise desses pares de valores e, para facilitar a classificação, desenvolveu-se uma nova rotina no *software* MatLab que, inclusive, apresenta a imagem classificada por limiarização (Apêndice B).

(iv) Etapa 4 - Avaliação do modelo

Para a classificação MaxVer e RNA, após o treinamento, as amostras de teste, coletadas independentemente, foram utilizadas para a validação dos resultados, nos quais foram geradas as matrizes de erro e índices derivados para as análises estatísticas.

Já na classificação por limiarização global a avaliação do resultado foi visual, comparando lado a lado a imagem original analisada com a sua classificação respectiva.

(v) Resultados e discussões

Os resultados da classificação das 60 amostras de teste independentes utilizando o classificador MaxVer estão apresentados na Tabela 5.2. Os resultados utilizando blocos de tamanho 8x8 e 16x16 *pixels* foram descartados, devido a classificação ter piorado significativamente.

Tabela 5.2 - Resultados da classificação MaxVer

IMAGEM	MATRIZ DE ERROS					PARÂMETROS
Imagem 1	Classe	1	2	Total	E.C.(%)	Kappa = 0,767
	1	28	5	33	15,2	Var. Kappa = 0,006802
	2	2	25	27	7,4	Z estatístico = 9,296
	Total	30	30	60		EG = 88,3%
	E.O.(%)	6,7	16,7			

Tabela 5.2 - Resultados da classificação MaxVer (cont.)

IMAGEM	MATRIZ DE ERROS					PARÂMETROS
Imagem 2	Classe	1	2	Total	E.C.(%)	Kappa = 0,700
	1	26	5	31	16,1	Var. Kappa = 0,008491
	2	4	25	29	13,8	Z estatístico = 7,597
	Total	30	30	60		EG = 85,0%
	E.O.(%)	13,3	16,7			
Imagem 3	Classe	1	2	Total	E.C.(%)	Kappa = 0,467
	1	27	13	40	32,5	Var. Kappa = 0,01158
	2	3	17	20	15	Z estatístico = 4,335
	Total	30	30	60		EG = 73,3%
	E.O.(%)	10	43,3			
Imagem 4	Classe	1	2	Total	E.C.(%)	Kappa = 0,733
	1	26	4	30	13,3	Var. Kappa = 0,007704
	2	4	26	30	13,3	Z estatístico = 8,355
	Total	30	30	60		EG = 86,7%
	E.O.(%)	13,3	13,3			
Imagem 5	Classe	1	2	Total	E.C.(%)	Kappa = 0,553
	1	20	4	24	16,7	Var. Kappa = 0,011449
	2	10	26	36	27,8	Z estatístico = 4,984
	Total	30	30	60		EG = 76,7%
	E.O.(%)	33,3	13,3			
Imagem 6	Classe	1	2	Total	E.C.(%)	Kappa = 0,633
	1	20	1	21	4,8	Var. Kappa = 0,009083
	2	10	29	39	25,6	Z estatístico = 6,645
	Total	30	30	60		EG = 81,7%
	E.O.(%)	33,3	3,3			

Onde: Classe 1 - RA sem defeito; Classe 2 - RA com defeito.

Em relação a classificação utilizando RNA, os resultados da classificação das 60 amostras de teste independentes estão apresentados na Tabela 5.3.

Tabela 5.3 - Resultados da classificação RNA

IMAGEM	MATRIZ DE ERROS					PARÂMETROS
Imagem 1	Classe	1	2	Total	E.C.(%)	Kappa = 0,600
	1	18	0	18	0	Var. Kappa = 0,008960
	2	12	30	42	28,6	Z estatístico = 6,339
	Total	30	30	60		EG=80%
	E.O.(%)	40	0			
Imagem 2	Classe	1	2	Total	E.C.(%)	Kappa = 0,833
	1	25	0	25	0	Var. Kappa = 0,004951
	2	5	30	35	14,3	Z estatístico = 11,843
	Total	30	30	60		EG = 91,7%
	E.O.(%)	16,7	0			
Imagem 3	Classe	1	2	Total	E.C.(%)	Kappa = 0,633
	1	29	10	39	25,6	Var. Kappa = 0,009083
	2	1	20	21	4,8	Z estatístico = 6,645
	Total	30	30	60		EG = 81,7%
	E.O.(%)	3,3	33,3			
Imagem 4	Classe	1	2	Total	E.C.(%)	Kappa = 0,700
	1	28	7	35	20	Var. Kappa = 0,008264
	2	2	23	25	8	Z estatístico = 7,700
	Total	30	30	60		EG = 85%
	E.O.(%)	6,7	23,3			
Imagem 5	Classe	1	2	Total	E.C.(%)	Kappa = 0,700
	1	25	4	29	13,8	Var. Kappa = 0,008491
	2	5	26	31	16,1	Z estatístico = 7,597
	Total	30	30	60		EG = 85%
	E.O.(%)	16,7	13,3			
Imagem 6	Classe	1	2	Total	E.C.(%)	Kappa = 0,800
	1	26	2	28	7,1	Var. Kappa = 0,005973
	2	4	28	32	12,5	Z estatístico = 10,351
	Total	30	30	60		EG = 90%
	E.O.(%)	13,3	6,7			

Onde: Classe 1 - RA sem defeito; Classe 2 - RA com defeito. O erro de omissão, erro de comissão e o índice Kappa já foram discutidos na sub-seção 4.6.1.4.

Para as seis imagens analisadas, tanto os dados classificados pelo MaxVer quanto pela RNA apresentaram resultados considerados de bons a muito bons, de acordo com a Tabela 4.3. Na classificação MaxVer a menor exatidão global (EG) foi igual a 73,3% (Imagem 3) e a maior igual a 88,3% (Imagem 1); o menor Kappa foi igual a 0,467 (Imagem 3) e o maior igual a 0,767 (Imagem 1). Já a menor exatidão global obtido com a RNA foi igual a 80% (Imagem 1) e a maior igual a 91,7% (Imagem 2); o menor Kappa foi igual a 0,600 (Imagem 1) e o maior igual a 0,833 (Imagem 2). Resumindo os resultados das seis imagens analisadas, os dados classificados por MaxVer, apontaram a Imagem 3 como pior classificada e a Imagem 1 foi a melhor classificada; quanto à classificação dos dados por RNA, a Imagem 1 pior classificada e a Imagem 2 foi a melhor classificada.

A RNA, de uma maneira geral, classificou melhor as imagens do que o MaxVer, mostrando o potencial desse algoritmo. Quanto aos extratores utilizados (ICW e média dos brilhos), formaram um par de valores que representaram bem as características das imagens analisadas. Outros pares de extratores foram usados em testes preliminares, mas com resultados muito aquém dos apresentados.

Os resultados obtidos na classificação por limiarização global estão apresentados na Figura 5.14.





NOME	IMAGEM	CLASSIFICADA	OBS
Imagem 1			ICW>10 MB<130
Imagem 2			ICW>10 MB<148

Figura 5.14 - Resultados da classificação por limiarização global








NOME	IMAGEM	CLASSIFICADA	OBS
Imagem 3			ICW>10 MB<135
Imagem 4			ICW>2 MB<147
Imagem 5			ICW>20 MB<160
Imagem 6			ICW>10 MB<100

Figura 5.14 - Resultados da classificação por limiarização global (cont.)

Onde: ICW - coeficiente definido pela Equação 5.15; MB - média do brilho.

Com exceção da Imagem 4 (remendo), as outras imagens tiveram uma boa classificação. A Imagem 3 (buraco) foi a melhor classificada, pois praticamente não teve ruídos e o defeito foi bem identificado. Nas outras imagens, embora haja ruídos, consegue-se sem dificuldades identificar os defeitos. Novamente, é bom ressaltar que as imagens usadas nos experimentos desse capítulo não tiveram qualquer tipo de tratamento e, na sua aquisição no campo, não se usou nenhum procedimento para padronizar sua qualidade.

(vi) Conclusões

Este experimento teve como objetivo analisar a possibilidade de se fazer a detecção dos defeitos superficiais de pavimentos asfálticos, com o uso de imagens terrestres, utilizando técnicas estatísticas de reconhecimento de

padrões, redes neurais artificiais (RNA) e limiarização global. Baseados nos testes desenvolvidos apresentam-se as seguintes conclusões.

A metodologia de particionar a imagem em blocos, aplicando em seguida a Transformada *Wavelet* e o conjunto dos extratores (ICW e média do brilho) para definir o vetor de característica dos blocos, mostrou-se bastante eficiente na classificação supervisionada das seis imagens analisadas.

Tanto a classificação utilizando o algoritmo MaxVer quanto RNA, apresentaram para as seis imagens analisadas bons índices de exatidão global e Kappa e o teste estatístico Z comprovou que a classificação foi significativamente melhor do que uma classificação aleatória. Em todas as seis imagens a RNA convergiu rapidamente e suas topologias foram simples, sendo quatro o maior número de neurônios na camada escondida.

No conjunto, os resultados da classificação por RNA foram superiores em relação os resultados obtidos na classificação usando o algoritmo MaxVer.

Quanto à classificação por limiarização global, de uma maneira geral, teve-se uma boa classificação, com exceção da Imagem 4 (remendo). A presença de ruídos em algumas imagens classificadas não dificultou a sua interpretação.

5.6.4.2. EXPERIMENTO 2 - USO DE MORFOLOGIA MATEMÁTICA

Continuando a proposta de analisar as seis imagens da subseção 5.6.4, procedendo à sua classificação, agora, utilizando-se morfologia matemática.

Morfologia matemática é uma ferramenta poderosa quando se pretende extrair feições lineares de imagem. Por não ser um método adaptativo, para que esta ferramenta se torne eficiente é necessário desenvolver uma série de testes sobre cada imagem, escolhendo adequadamente o elemento estruturante e a sequência de operação

morfológica que será aplicada. Dessa forma, exaustivos testes foram efetuados sobre as imagens com a intenção de se obter a melhor sequência de operações morfológicas e que destacasse os defeitos sobre as imagens analisadas. Já se sabia, de antemão, que a imagem com remendo não teria resultados animadores, pois o defeito remendo não é uma feição linear e sim superficial.

A metodologia adotada consistiu na definição da sequência de operações morfológicas que atendesse a maioria das imagens analisadas. Desenvolver uma sequência para cada imagem tornaria desgastante e desinteressante o procedimento. A sequência de operações ficou conforme apresentado na Figura 5.15.



Figura 5.15 - Etapas da metodologia utilizando operadores morfológicos

A primeira consideração sobre a metodologia é que não haveria qualquer tipo de pré-processamento da imagem para melhorar, por exemplo, o seu contraste. Adotando esse procedimento, pretendia-se garantir que o resultado final não seria influenciado por um pré-processamento da imagem.

Sobre a imagem em tons de cinza aplicou-se o operador *erosão* (repetidamente ou não). Em seguida fez-se a binarização da imagem, aplicou-se novamente o operador *erosão* (repetidamente ou não), porém agora sobre a imagem binarizada. Após, verificando-se que a imagem tinha uma aparência um pouco grosseira (aspecto “bloqueada”), aplicava-se um filtro para suavizá-la. Nesse caso, optou-se por um filtro de mediana.

(i) Etapa 1 - Aplicação do operador morfológico *erosão*

Em todas as imagens analisadas aplicou-se duas vezes o operador morfológico *erosão*, que foi o suficiente para destacar os defeitos das imagens.

(ii) Etapa 2 - Binarização da imagem

Nesta etapa, para binarizar cada imagem utilizou-se um limiar global.

(iii) Etapa 3 - Aplicador do operador morfológico *erosão*

Sobre as imagens binarizadas aplicou-se duas vezes o operador morfológico *erosão*. Esta operação teve por finalidade eliminar ruídos e afinar as feições lineares das imagens (trincas).

(iv) Etapa 4 - Aplicação do filtro da mediana

Nas imagens obtidas na etapa (iii), as feições lineares (trincas) têm uma aparência grosseira, denominada “blocada”, ou seja, seus contornos são formados por blocos de quina reta. A aplicação do filtro da mediana dá uma aparência mais suave às feições lineares, além de, eliminar pequenos ruídos da imagem.

(v) Resultados e discussões

Os resultados da classificação das imagens com o uso de operadores morfológicos estão apresentados na Figura 5.16. Para destacar o potencial desse procedimento, achou-se interessante colocar a imagem binarizada para comparar lado a lado com o resultado obtido através da morfologia matemática.

As imagens cujos defeitos são feições lineares (trincas) tiveram uma boa representação. Ficaram alguns ruídos nas bordas das imagens, mas que não comprometeram a interpretação dos defeitos.

A imagem 3 (buraco) mostrou um resultado surpreendentemente bom. A imagem final apresentou-se bastante limpa, praticamente livre de ruídos.












NOME	IMAGEM	IMAGEM BINARIA	CLASSIFICADA
Imagem 1			
Imagem 2			
Imagem 3			
Imagem 4			
Imagem 5			
Imagem 6			

Figura 5.16 - Resultados da classificação utilizando morfologia matemática

A imagem 4 (remendo), como já se previa, apresentou um resultado ruim, com muitos ruídos e de difícil análise.

(vi) Conclusões

Face aos resultados obtidos nesse experimento pode-se afirmar que, analisar trincas e buracos sobre imagens do pavimento asfáltico com o uso de morfologia matemática apresenta um bom resultado para interpretação visual. Além disso, definido a sequência de operações sobre a imagem, passa a ser possível uma análise automática, através de uma implementação computacional. A imagem classificada ficou com alguns ruídos, mas não há dificuldades em interpretá-las.

5.7. RESUMO DO CAPÍTULO

Como resumo desse capítulo, abordou-se a textura para discriminar defeitos na superfície dos pavimentos asfálticos com o uso de imagens monocromáticas, indicando uma metodologia para seleção das medidas texturais que maximize a discriminação entre os defeitos analisados. Para tanto, usou-se Transformada *Wavelet*, limiarização e Morfologia Matemática.

Pode-se considerar que todos os procedimentos utilizados apresentaram bons resultados e as metodologias propostas podem ser utilizadas para o reconhecimento automático de padrões de defeitos superficiais de pavimentos com o uso de imagens terrestres monocromáticas.

Ressalta-se que os defeitos analisados nesse capítulo foram tratados individualmente (um tipo de defeito por imagem), mas, na prática, em termos operacionais, os defeitos são tratados coletivamente, ou seja, é comum ter-se mais de um defeito por imagem.

CAPITULO 6

DISCRIMINAÇÃO DAS CAMADAS DO PAVIMENTO ATRAVÉS DA TEXTURA

Nesse capítulo, são utilizadas imagens do perfil subsuperficial do pavimento, obtidas com o *Ground Penetration Radar* (GPR), na tentativa de identificar automaticamente as camadas que compõem o pavimento, visto que esse procedimento é feito por interpretação visual da imagem. Para tanto, utilizou-se a mesma metodologia do Capítulo 5, usando a Transformada *Wavelet* para a extração da textura da imagem e posterior uso no processo de classificação. Os resultados apontam para uma grande possibilidade neste procedimento.

6.1. INTRODUÇÃO

Há uma relação intrínseca entre as condições das camadas (fadiga, processo construtivo, etc) que compõem um pavimento e alguns defeitos que aparecem na superfície do revestimento (PINTO e PREUSSLER, 2001). Portanto, a investigação e o acompanhamento da situação das camadas do pavimento ao longo do tempo é uma forma de prever as condições futuras de rolamento do revestimento. Informações sobre a camada do pavimento, como sua espessura, umidade, densidade, composição, etc, são essenciais para uma boa análise.

No Brasil, a maioria dos métodos usuais para análise das camadas do pavimento são invasivos, pontuais, de custos elevados e necessitam de operações de desvio de trânsito na via, motivos mais que suficientes para serem pouquíssimos usados como métodos preventivos.

Felizmente, novas tecnologias vêm surgindo e, neste segmento, aparece o Radar de Penetração no Solo, também conhecido como georradar ou simplesmente GPR. O GPR é um método geofísico, não destrutivo, de alta resolução, que permite obter uma imagem da subsuperfície rasa da

Terra (feições geológicas rasas ou objetos enterrados pelo homem), utilizando reflexões de ondas eletromagnéticas em altas frequências, normalmente entre 10 e 2.500 MHz.

O princípio de funcionamento do GPR é apresentado na Figura 6.1. Uma antena transmissora emite um pulso eletromagnético (comprimento de onda na faixa das microondas e radiofrequência) para dentro da Terra e, devido às mudanças das propriedades dielétricas dos materiais da subsuperfície, parte do sinal transmitido é refletido, refratado e disperso. O sinal refletido, por sua vez, é detectado por uma antena receptora no qual é amplificado, digitalizado e armazenado, para ser processado e transformado em registro, que pode ser um sinal ou uma imagem, sendo essa última denominada radargrama (BORGES e PORSANI, 2005).




Figura 6.1 - Princípio de funcionamento do GPR
Fonte: modificado de Marques (2007)

As antenas posicionam-se dentro de suas respectivas unidades, as quais são formadas por módulos eletrônicos conectados à unidade de controle através de cabos ópticos. O computador portátil é conectado à unidade de controle por cabo de comunicação paralelo.

As antenas (transmissoras e receptoras) podem estar em contato com a superfície, denominadas *antenas de arraste*, ou ligeiramente afastadas da

superfície, sendo denominadas *antenas horn*.

Obtém-se com o GPR uma imagem de alta resolução da subsuperfície, na qual o eixo horizontal representa a distância percorrida com as antenas e o eixo vertical representa o tempo de ida e volta do sinal, ou a profundidade alcançada pelo sinal.

Na Figura 6.2 (a) vê-se um arranjo do equipamento em três posições diferentes, o sinal emitido/recebido em cada posição e uma anomalia¹ sendo interceptada pelos sinais. Na Figura 6.2 (b), visualiza-se uma hipérbole no radargrama, que caracteriza uma anomalia na subsuperfície. Quanto maior o alvo, mais ampla é essa hipérbole.




Figura 6.2 - Interpretação do radargrama
(a) - arranjo espacial com o GPR em 3 posições diferentes;
(b) - visualização de uma anomalia, através do radargrama.
Fonte: Davis e Annan (1989)

Segundo Benson e Noel (1984), uma das razões da popularidade do GPR em relação a outros métodos geofísicos é seu formato gráfico contínuo e de alta resolução. Os dados são interpretados pelo aspecto visual, na tela de um *notebook* ou impresso, permitindo uma rápida análise das estruturas e anomalias encontradas.

Com o GPR não se consegue medir diretamente a profundidade de um alvo. Ele permite medir o tempo que um sinal eletromagnético gasta para ir da antena transmissora até uma superfície refletora e voltar até a antena receptora, denominado *tempo de trânsito*, que é medido em nanosegundos (ns).

¹ *Anomalias* são estruturas isoladas e enterradas, podendo ser natural ou artificial e que se apresentam no radargrama como hipérboles.

A calibração do GPR consiste, no local de trabalho, em determinar o tempo que um sinal gasta para ir até um alvo de profundidade conhecida e retornar. Na seção 6.4.1 abordam-se dois métodos de calibração.

O termo “pegada do GPR” ou “GPR footprint” corresponde ao cone de energia (A = semi-raio e $B = 2A$) que abrange uma área da subsuperfície devido ao sinal irradiado pela antena transmissora do GPR (LOPES, 2009). Na Figura 6.3 observa-se a área em profundidade atingida pelo sinal da antena transmissora do GPR representada pela região em destaque.




Figura 6.3 - Representação da “pegada do GPR”
Fonte: Lopes (2009)

O valor do semi-raio (A) depende da profundidade (D), do comprimento da onda (λ) e da constante dielétrica (K), conforme a Equação 6.1.

$$A = (\lambda/4) + (D/\sqrt{K-1}) \quad (6.1)$$

Os dados obtidos pelo GPR são interpretados pela análise das características das microondas e rádio frequências ao atravessar um meio. O estudo das descontinuidades subsuperficiais obtidas por reflexão de ondas eletromagnéticas são basicamente devido a quatro fenômenos e seus respectivos índices físicos: a) *os que determinam a velocidade de propagação da onda em cada material* - permissividade dielétrica (ϵ); b) *os que limitam a penetração da energia no meio* - condutividade elétrica (σ); c) *os que determinam o percentual de energia refletida e transmitida em cada contato* - permeabilidade magnética (μ); d) *os que afetam a resolução da imagem* - frequência da emissão (f). Os 3 primeiros fenômenos são características do

meio e o último depende do equipamento utilizado (AGUIAR, 2005).

A interpretação dos dados GPR é essencialmente qualitativa. Sabe-se que alvos isolados aparecem como hipérboles, e que regiões mais condutivas eletricamente causam uma atenuação dos sinais eletromagnéticos.

Quanto às aplicações do GPR, é comum dividi-las em duas categorias: aplicações geológicas e aplicações em geofísica rasa.

Nas aplicações geológicas, o alcance da onda eletromagnética é mais importante que a resolução do radargrama e, para tanto, utilizam-se antenas de frequências menores, até 500 MHz.

A Figura 6.4 apresenta a relação entre os seguintes parâmetros do GPR: frequência, comprimento de onda, resolução e profundidade de penetração.




Figura 6.4 - Relação entre frequência, comprimento de onda, resolução e profundidade de penetração do GPR
Fonte: Lopes (2009)

Na geofísica rasa, enfoque desta tese, prevalece a resolução do radargrama como elemento mais importante e, nesse caso, a onda eletromagnética penetra pouco na subsuperfície. Utilizam-se antenas de frequências mais elevadas, acima de 500 MHz.

Ressalta-se que a facilidade (ou dificuldade) de interpretação das

imagens obtidas com o GPR, depende de haver (ou não haver) no radargrama contrastes entre as diferentes regiões contíguas da subsuperfície, conforme apresentado na Figura 6.5. A camada *a* e camada *b* da Figura 6.5 são facilmente identificáveis (pela textura apresentada). Inclusive, observa-se, sem qualquer dificuldade, uma linha que representa a interface entre elas.




Figura 6.5 - Radargrama, apresentando o contraste entre as camadas da subsuperfície
Fonte: adaptado de Aguiar (2005)

Além disso, como todo e qualquer método geofísico, a qualidade da interpretação dos dados obtidos em campo depende basicamente de dois fatores: a) experiência do profissional; b) utilização de métodos diretos para confirmação de resultados.

6.2. REVISÃO DA LITERATURA

O uso do GPR no Brasil, em atividades de pesquisas relativas ao pavimento rodoviário, ainda é um ramo pouco explorado. No mundo, registram-se vários trabalhos nessa área. Procurou-se, nesta revisão da literatura, relatar tanto trabalhos nacionais como trabalhos internacionais.

Saarenketo (1997) comparou dois métodos baseados na medida da permissividade dielétrica do meio aplicado ao pavimento: o GPR e a sonda de superfície baseada na capacitância. A medida da permissividade dielétrica com esses equipamentos pode ser usada para medir variações dos vazios e/ou no conteúdo de betume em pavimentos asfaltados recentemente. A compactação reduz a proporção de vazios do RA com conseqüente diminuição de volume da massa e o resultado são valores da

permissividade dielétrica do RA compactado maior do que o RA seco. Os resultados de campo podem ser calibrados comparando com dados do mesmo material ensaiado em laboratório, relacionando a permissividade dielétrica com vazios da mistura. Como conclusão, Saarenketo (1997) cita que o uso desses sensores possibilita rapidez nas medidas e a disponibilidade imediata dos resultados, além de serem métodos não invasivos.

Gonçalves e Ceratti (1998) evidenciaram a potencialidade do GPR para obtenção de parâmetros que auxiliam na previsão e acompanhamento do comportamento estrutural do pavimento, determinando a espessura e verificando as condições em que se encontravam os materiais das camadas do pavimento. Determinaram, também, a presença de bolsões de ar sob placas de concreto de cimento. O trabalho baseou-se em uma área teste localizada no campus da Universidade Federal do Rio Grande do Sul, utilizando sondagens para calibração dos dados do GPR. Determinaram a velocidade de propagação da onda do radar com o arranjo CMP. Os trabalhos foram realizados em duas etapas: a primeira, arrastando o radar manualmente, em seções testes e a segunda etapa, arrastando o radar em um veículo. A antena utilizada foi de 1 MHz.

Olhoeft e Smitt III (2000) utilizaram um GPR marca GSSI, modelo SIR-8, com antena *horn* (sem contato) de 1GHz, adquirindo dados de um veículo em movimento, para determinar a espessura, a umidade e a permissividade dielétrica de camadas de pavimento de concreto e de RA. Desenvolveram algoritmos para adquirir os dados, calibrar automaticamente, processar e modelar a forma da onda, tudo sem intervenção de operador. Foram gerados parâmetros estatísticos e histogramas para as espessuras e permissividade dielétrica de pavimentos de concreto ou de RA. A incerteza estatística com que a espessura é determinada é calculada para cada medida de espessura, junto com a permissividade dielétrica do material do pavimento e do subleito. Obtiveram incertezas estatísticas típicas em espessura inferiores a 0,4 cm em camadas de 20 cm.

Olhoeft e Selig (2002) desenvolveram um experimento com o GPR para mapear continuamente a superestrutura de uma via férrea. No estudo, utilizaram antena de 1 GHz e os dados eram adquiridos até uma profundidade de 1,5 m, com o GPR fixo a um veículo adaptado para transitar sobre a linha férrea e movendo a cerca de 20 km/h - Figura 6.6. Foram observadas as condições da superestrutura, como espessura do lastro e das camadas do sublastro, variações nas espessuras das camadas ao longo da linha férrea, bolsões de água no lastro e umidade das camadas do sublastro. Localizações e profundidades dos drenos profundos, trincheiras e outras interferências também foram obtidos. Concluíram os autores que o GPR mostrou qualidades para mapear os dados do lastro, sublastro e drenagem de uma linha férrea.



Figura 6.6 - Antenas GPR montadas em uma estrutura adaptada a um veículo que percorre a via férrea
Fonte: Olhoeft e Selig (2002)

Um projeto muito interessante e que vale a pena ser citado é o trabalho de Borges e Porsani (2003). Muito embora não tenha aplicação direta na atividade rodoviária, o destaque dessa pesquisa é para análise de alvos enterrados, cujos resultados são úteis nas interpretações das anomalias, independentes da aplicação específica. O trabalho constou da criação de uma área (próxima ao Instituto de Física, localizado em frente ao Instituto de Astronomia, Geofísica e Ciências Atmosféricas da USP, compreendendo uma extensão de 1500m²) para testes controlados de geofísica rasa. As ambigüidades presentes nas interpretações dos dados geofísicos podem ser amenizadas, e em certos casos, até eliminadas. Nestas áreas, as geometrias dos alvos, os seus conteúdos, as propriedades físicas e profundidades são

conhecidas, auxiliando o intérprete a definir os melhores parâmetros para a interpretação através dos resultados obtidos. Vários alvos com dimensões e profundidades diferentes foram enterrados ao longo de sete linhas, visando simular estudos geológicos, geotécnicos, arqueológicos, ambientais e de planejamento urbano. Os alvos foram escolhidos para terem respostas eletromagnéticas, condutivas ou para terem reflexões nos perfis GPR. Os dados geofísicos são adquiridos “antes” e “depois” da instalação do sítio controlado, o que permite a caracterização geofísica dos alvos enterrados. Essa caracterização consiste em avaliar o desempenho e a confiabilidade dos métodos geofísicos de investigação rasa quando aplicados sobre alvos cujas propriedades físicas e geométricas são conhecidas. Os principais métodos geofísicos utilizados são: eletromagnético indutivo, GPR, eletrorresistividade, polarização induzida e magnetometria. As assinaturas geofísicas obtidas com cada método são analisadas, visando obter padrões de respostas típicas para cada tipo de material, contribuindo para a nossa habilidade em interpretar dados geofísicos.

Aguiar (2005) analisou o desempenho do GPR como ferramenta para a definição do substrato de pavimento rodoviário flexível. Foram escolhidas duas área testes, uma bastante deteriorada (com defeitos e recalques) e outra bem conservada. Utilizou antenas de 200 e 400 MHz, o que limitou uma melhor definição dos refletores. As observações foram realizadas atravessando as estações de seca e chuva, tendo sempre a preocupação de observar o nível freático local. Concluiu que a ferramenta GPR é um poderoso recurso para avaliação de pavimentos, pois possibilita, de forma indireta, a análise das condições estruturais de uma via rodoviária. No entanto, sua aplicação deve ser feita cautelosamente, visto que mesmo para os equipamentos mais sofisticados aparecem limitações quando comparadas com técnicas invasivas.

Amer-Yahia e Majidzadeh (2006) desenvolveram uma pesquisa em uma estrada de área residencial na cidade de Colombo, Ohio para investigar o uso de GPR na determinação da porcentagem de vazios em camadas asfálticas executadas recentemente. Afirmam os autores que o GPR pode ser considerado como a melhor alternativa para o controle de compactação de

camada asfáltica nova, pois além de ser um método não destrutivo, pode ser executado sem interferir nas faixas de trânsito e, principalmente, disponibiliza informação contínua ao longo do trecho inspecionado.

Paixão *et al.* (2006) utilizaram o GPR para estimar teores de umidade de solos superficiais em uma área teste na cidade de São Paulo, a partir de duas metodologias diferentes: a) ajuste linear dos tempos de chegada da onda direta no solo para diferentes afastamentos; b) diferenças dos tempos de chegada da onda aérea e da onda direta no solo para um único afastamento. No experimento utilizaram antenas de 50 MHz, 100 MHz e 200 MHz e a aquisição de dados constituiu-se de diversos perfis *multi-offset* (múltiplos afastamentos) com o emprego da geometria WARR (*Wide Angle Reflection and Refraction*) ao longo de um perfil em três períodos climáticos distintos (seco, intermediário e úmido). O incremento entre os traços dos perfis *multi-offset* foi de 0,2 m para a antena de 50 MHz e 0,1 m para as antenas de 100 MHz e 200 MHz. Comparando os dados do GPR com os dados de campo concluíram que houve uma boa correlação, sendo que os dados obtidos com as antenas de frequência de 200 MHz propiciaram os melhores resultados e que os dois métodos empregados apresentaram resultados diferentes.

Saarenketo (2006) relata que os resultados de testes de laboratório apresentados no seu trabalho mostram que a relação entre o valor da permissividade dielétrica e o aumento do conteúdo de água não é linear e nem exponencial, mas semelhante a uma série de funções logarítmicas. Os resultados de laboratório também mostraram que dispersão da permissividade dielétrica pode ser fracamente relacionada a solos de subleito e agregados da rodovia. Por outro lado, a permissividade dielétrica é fortemente relacionada com materiais umedecidos com água de adsorção e água capilar. O valor da permissividade dielétrica e a condutividade elétrica também podem ser relacionados a outras propriedades de materiais da estrada e solos do subleito como o limite de plasticidade, grau de compactação e conteúdo de vazios. Concluindo, Saarenketo (2006) afirma que a técnica de GPR não só dá valiosa informação estrutural nos tipos diferentes de estruturas e solos do subleito, mas também informações sobre as propriedades elétricas dos materiais da

subsuperfície, que podem ser posteriormente relacionados ao desempenho mecânico do pavimento.

Lopes (2009) procurou correlacionar dados deflectométricos, obtidos com a viga Benkelman, com o radargrama, através de elementos de identificação da estrutura do pavimento. Utilizou um GPR da marca IDS, com antenas de 600 MHz e 1,6 GHz de frequência. O local dos experimentos foi o sistema viário do campus da Universidade Federal do Rio de Janeiro (UFRJ), Ilha do Fundão. A transição entre camadas (interface) foi identificada pela presença de fortes marcadores, favorecendo a determinação da espessura de camadas com o emprego do GPR. Lopes (2009) concluiu que *“o GPR é um método viável de ser aplicado para melhor interpretação da condição estrutural de um pavimento feita a partir da deflexão, por proporcionar o conhecimento mais detalhado da estrutura do pavimento existente, facilitando a retroanálise das bacias e assim, ajudando a aquisição de parâmetros suficientes para definir intervenção de restauração e direcionamento dos recursos disponíveis”*.

Resumindo os relatos dos trabalhos citados nessa seção, pode-se utilizar o GPR para obter, de uma forma não invasiva as seguintes informações do pavimento: a) espessura das camadas; b) presença de bolsas de ar e água; c) umidade das camadas; d) densidade do revestimento lançado recentemente; e) distribuição dos materiais das camadas; f) drenagem não superficial.

Na próxima seção discorre-se sobre o princípio de funcionamento do GPR.

6.3. ENTENDENDO O PRINCÍPIO DE FUNCIONAMENTO DO GPR

A constante dielétrica K , é, por definição, $K = \varepsilon / \varepsilon_0$, onde ε é a permissividade dielétrica² do meio e ε_0 é a permissividade dielétrica do vácuo (8,854 pF/m). A constante dielétrica é adimensional.

² Permissividade dielétrica é um parâmetro físico que descreve como um campo elétrico afeta e é afetado por um meio.

A velocidade de propagação do pulso do GPR pode ser expressa por $v = c/K$, onde c é a velocidade da onda eletromagnética no vácuo (0,3 m/ns).

A atenuação (α), ou seja, a perda de sinal do pulso do GPR, é determinada pela equação: $\alpha = 1,96 \frac{\sigma}{K}$, onde σ é a condutividade elétrica.

O princípio básico de funcionamento do GPR é o tempo que um sinal leva, após ter sido emitido pela antena transmissora, para ser detectado na antena receptora, depois da reflexão do sinal em uma interface (duplo tempo).

Há três parâmetros cujo conhecimento e comportamento são importantes para investigar a subsuperfície: a) velocidade das ondas eletromagnéticas no meio; b) reflexão das ondas eletromagnéticas nas interfaces; c) polarização das ondas eletromagnéticas no meio.

6.3.1. A VELOCIDADE DAS ONDAS

A velocidade das ondas de radar depende das propriedades elétricas do meio por onde passa sendo a permissividade dielétrica (ϵ) a principal delas.

Já a atenuação das ondas de radar (dificuldade de penetração) é controlada pela condutividade elétrica (σ); alta condutividade causa uma forte atenuação dos sinais eletromagnéticos, ou seja, o sinal penetra menos nas estruturas subsuperficiais.

As propriedades elétricas das camadas subsuperficiais dependem de sua composição e do conteúdo de água. O sucesso da aplicação do método GPR depende da capacidade do meio em transmitir o seu sinal. Por exemplo, argila saturada absorve completamente as ondas de radar, impedindo sua penetração no meio.

A Tabela 6.1 apresenta algumas propriedades físicas consideradas

importantes para o uso do GPR e seus valores para determinados materiais. A umidade influencia muito na velocidade do pulso, fato comprovado, por exemplo, observando seu valor na areia seca e na areia saturada. Quanto maior a umidade, menor a velocidade do sinal e mais difícil a sua captação (grande atenuação).

Tabela 6.1 - Algumas propriedades físicas importantes para o uso do GPR e seus valores para determinados materiais.
Fonte: modificado de Marques (2007)

MATERIAL	CONSTANTE DIELÉTRICA $K^{(3)}$	VELOCIDADE DO PULSO V (m/ns)⁽⁴⁾	CONDUTIVIDADE σ (mS/m)⁽⁵⁾
Ar	1	0,3	0
Água doce	81	0,033	0,10 – 30
Água do mar	81	0,033	400
Areia seca	3 – 6	0,12 – 0,17	0,0001 – 1
Areia saturada	25 – 30	0,055 – 0,060	0,1 – 1
Silte saturado	10	0,095	1 – 10
Argila seca	3	0,173	-
Argila saturada	8 – 15	0,086 – 0,110	100 – 1000
Gelo água doce	4	0,15	0,1 – 10
Granito seco	5 - 8	0,106 – 0,120	0,00001
Dolomita	6 – 8	0,106 – 0,115	-
Quartzo	4	0,145	-
Carvão	4 – 5	0,134 – 0,150	-
Concreto	5 – 8	0,055 – 0,120	0,5 – 1,5
RA	3 – 5	0,134 – 0,173	0,05 – 0,5

A presença da água nas rochas afeta consideravelmente a sua constante dielétrica chegando a valores dez vezes maiores em relação o valor da constante dielétrica se a rocha estiver totalmente seca. Se a água tiver salinidade, o valor pode ser ainda maior (MARQUES, 2007).

³ K é adimensional;

⁴ m/ns – metro por nanosegundos;

⁵ mS/m – miliSiemens por metro.

A propagação das ondas eletromagnética nas frequências do GPR está na fronteira entre a difusão⁶ e a irradiação⁷. Uma ou outra pode tornar-se dominante, dependendo do material. Por exemplo: em materiais com condutividade elétrica (σ) alta, a difusão é dominante e tem-se uma alta atenuação; já em materiais com condutividade elétrica (σ) baixa, a irradiação é dominante e tem-se uma baixa atenuação.

6.3.2. A REFLEXÃO DAS ONDAS

Devido à dispersão das ondas eletromagnéticas, as altas frequências são atenuadas mais rapidamente, resultando em uma distorção do pulso ao longo da trajetória. A energia da onda refletida na interface é dada pelo coeficiente de reflexão R , conforme Equação 6.2, sendo v_1 e v_2 a velocidade da onda eletromagnética no meio 1 e 2, respectivamente; K_1 e K_2 a constante dielétrica do meio 1 e 2, respectivamente.

$$R = (v_2 - v_1)/(v_2 + v_1) = (\sqrt{K_1} - \sqrt{K_2})/(\sqrt{K_1} + \sqrt{K_2}) \quad (6.2)$$

A Tabela 6.2 apresenta o valor do coeficiente de reflexão R para incidência normal sobre o solo seco e solo saturado em contato com o ar.

Tabela 6.2 - Valor do coeficiente de reflexão R entre 2 meios
Fonte: Annan (1992)

MEIO 1	MEIO 2	R
Ar K=1	Solo seco K=5	-0,38
Ar K=1	Solo saturado K=25	-0,67

O coeficiente de reflexão R pode ser positivo ou negativo, dependendo apenas dos meios que se está analisando. Se a onda do radar vai de um meio com constante dielétrica menor para outro de constante dielétrica maior, o valor

⁶ *Difusão* é o espalhamento da onda eletromagnética, devido à sua passagem por meios que contêm pequenas partículas ou irregularidades microscópicas;

⁷ *Irradiação* é a característica da onda eletromagnética desenvolver-se a partir de um ponto para as áreas circundantes.

de R é negativo. Caso contrário, o valor de R é positivo.

Na seção seguinte, aborda-se a polarização elétrica das ondas eletromagnéticas.

6.3.3. POLARIZAÇÃO ELÉTRICA DAS ONDAS

Quando se aplica um campo elétrico externo em um material, as cargas se movimentam separando-se até uma distância suficiente para criarem um campo elétrico interno que contrabalanceie o campo externo aplicado. Esta separação das cargas em determinada distância, na qual ocorre um armazenamento de energia, é que se denomina polarização elétrica, sendo a permissividade dielétrica ϵ quem traduz a capacidade do material de sustentar esse armazenamento (MARQUES, 2007).

Segundo Olhoeft (1998), as propriedades elétricas dos materiais têm duas componentes: uma responsável pelo transporte das cargas elétricas, medida pela condutividade elétrica σ e a outra responsável pelo armazenamento das cargas elétricas, medida pela polarização elétrica. O GPR é um equipamento que trabalha com altas frequências, assim, os efeitos da polarização elétrica sobressaem em relação à condutividade elétrica.

6.4. O MÉTODO GPR

Para utilizar o GPR no campo uma série de considerações deve ser previamente analisada. Normalmente, são elas: a) aquisição dos dados; b) frequência de operação; c) influência das camadas da subsuperfície; d) ruídos; e) configuração das antenas. Nas subseções seguintes (6.4.1 a 6.4.5) discorre-se sobre essas considerações.

6.4.1. AQUISIÇÃO DOS DADOS

Quando uma única antena é utilizada tanto como transmissora e receptora, a aquisição é dita *mono-estática*. Se houver duas antenas separadas, uma transmitindo o sinal e outra recebendo, a aquisição é dita *bi-estática*.

O modo mais comum para a aquisição dos dados GPR é através do *modo reflexão* (*common offset*), que consiste em se manter a distância entre as antenas constante (emissora e receptora). O sinal é transmitido, recebido e gravado em cada tempo que as antenas se movimentam em distâncias fixas ao longo do perfil investigado, conforme Figura 6.2 (a). É o procedimento padrão da aquisição de dados, denominada *mono-estática*.

Outro modo de aquisição de dados é pelo método denominado *trans-iluminação*, no qual a antena emissora e a antena receptora são dispostas em lados opostos em relação o local investigado. A antena transmissora é deslocada em posição simetricamente oposta em relação à antena receptora. Já esta, permanece fixa. Esse tipo de arranjo é indicado quando se pretende fazer avaliações em peças estruturais (identificar fissuras, vazios, etc), como em pilares, vigas e lajes. É uma aquisição de dados denominada *bi-estática*.

A Figura 6.7 apresenta a configuração dos modos de aquisição de dados dos dois métodos citados.




Figura 6.7 - Modos de aquisição de dados pelo GPR
Fonte: Marques (2007)

Se, agora, o propósito é obter, no campo, a velocidade de propagação da onda eletromagnética em um meio qualquer, utiliza-se os procedimentos denominados *Ponto Médio Comum* (CMP) ou *Reflexão e Refração de Grande Ângulo* (WARR). São aquisições de dados *bi-estáticos*.

O arranjo CMP consiste em aumentar progressivamente e simetricamente em relação a um ponto central, a distância entre as antenas,

emissora e receptora, possibilitando, assim, a determinação do valor da velocidade da onda eletromagnética no meio em que se propaga, utilizando o tempo de propagação da onda em cada posicionamento das antenas - Figura 6.8.




Figura 6.8 - Arranjo CMP
Fonte: Lopes (2009)

No arranjo WARR a antenna transmissora é mantida fixa e a antenna receptora é deslocada ao longo do caminhamento. Na Figura 6.9 é apresentado o gráfico “distância x tempo” em um arranjo WARR, relacionados à emissão, reflexão e refração da onda eletromagnética. Quando a antenna transmissora emite a onda, parte se propaga no ar (onda aérea), parte se propaga na direção da antenna receptora (onda direta) e parte se propaga na direção da subsuperfície - Figura 6.9 (b). A refração é dita crítica quando o ângulo de reflexão e o ângulo de refração são iguais (Θ_c).




Figura 6.9 - Arranjo WARR e gráfico tempo x distância
Fonte: Lopes (2009)

Agora, fazendo-se uma correspondência entre a Figura 6.9 (a) e Figura 6.9 (b), verifica-se que tanto a onda direta quanto a onda aérea saem no tempo $t=0$ da antena transmissora (b) e percorre uma distância que varia diretamente com o tempo, sendo a onda aérea mais rápida (a). Após um tempo $t = t_0$ a onda é refletida na interface (b) e em (a) tem-se sua curva característica (não linear). Quanto à onda refratada, tem o mesmo comportamento da onda aérea, porém defasada no tempo (a).

6.4.2. ESCOLHA DA FREQUÊNCIA DE OPERAÇÃO

A escolha da frequência de operação do GPR é devido a se obter a melhor relação entre a penetração do sinal e a resolução do alvo em estudo. Altas frequências relacionam-se com altas resoluções e baixas profundidades de penetração do sinal. Já as baixas frequências relacionam-se com baixas resoluções das imagens e altas profundidades de penetração do sinal.

Essas altas profundidades, via de regra, não ultrapassam 10 m, uma vez que o uso do GPR é para profundidades consideradas rasas. No entanto, existe relato de investigação feita com um GPR, com frequência de 1 a 1.000 MHz, obtendo um perfil da subsuperfície atingindo, nas camadas polares, 5.400 m (OLHOEFET, 1992).

6.4.3. INFLUÊNCIA DAS CAMADAS DA SUBSUPERFÍCIE

A atenuação é o resultado da conversão de energia eletromagnética em energia térmica, devido à condutividade dos materiais (σ). No caso do sinal GPR, a atenuação nos materiais da subsuperfície (solo, rocha, água) é um dos fatores que limita a sua penetração para alcançar profundidades maiores. Altas condutividades, como por exemplo, sais dissolvidos e aumento no teor de argila, provocarão altas atenuações no sinal.

Um fator relevante, também a considerar, é o teor de umidade, pois a água tem um valor dielétrico alto (baixa penetração do sinal) comparado com a rocha e o solo.

6.4.4. RUÍDOS

No GPR a intensidade dos ruídos captados pela antena receptora é muito forte. O método GPR é sensível a várias influências externas. Tem-se a destacar a onda aérea refletida em obstáculos acima da superfície do terreno, gerando um ruído que afeta fortemente o sinal GPR. Isto é devido ao sinal do radar se propagar quase sem atenuação pelo ar e ter uma amplitude muito maior do que a onda que emerge na subsuperfície. Assim, quando a onda aérea encontra obstáculos como postes, veículos, cercas, linhas de transmissão, árvores, construções, etc, ela reflete nesses elementos e retorna para o receptor, chegando com uma amplitude muito mais forte do que a onda refletida do interior da subsuperfície, se interpondo fortemente ao sinal das reflexões das ondas primárias⁸, sendo de difícil extração no processamento.

Como exemplo, Xavier Neto (2006) cita um ruído associado à reflexão da onda aérea em obstáculo superficial. Próximo à área em que se utilizava um GPR - Figura 6.10 (b), há três tanques que aparecem como ruído no radargrama (eventos hiperbólicos) - Figura 6.10 (a).

Hoje, alguns modelos comerciais de antena são concebidos para a eliminação da onda aérea. São as chamadas *antenas blindadas*, onde o sinal somente é enviado para o interior da estrutura.




Figura 6.10 - Exemplo de ruído associado à reflexão do sinal aéreo
(a) ruídos presentes no radargrama - 3 hipérboles devidas à reflexão de onda aérea;
(b) área de utilização do GPR próxima a 3 tanques
Fonte: Xavier Neto (2006)

⁸ Onda primária é aquela em que o movimento das vibrações das partículas ocorre na mesma direção de propagação da onda.

Ainda, segundo Xavier Neto (2006), há outros dois ruídos que são característicos do GPR. São eles: a) a indução eletromagnética entre as antenas; b) o WOW. Esses dois ruídos provocam uma saturação de alta amplitude e baixa frequência a poucos comprimentos de onda da fonte, fazendo desaparecer pouco a pouco as camadas mais rasas - Figura 6.11. Ambos os ruídos devem ser atenuados nas etapas iniciais do processamento para não prejudicarem a atuação de outros processos subsequentes.

A *indução eletromagnética entre as antenas* (emissora e receptora) interfere com as deflexões de camadas rasas e aparece no radargrama como uma feição em “trilho de trem”, bandeada, de alta amplitude e baixa frequência, atravessando toda a extensão do radargrama em seu trecho superior - Figura 6.11.




Figura 6.11 - Efeito no radargrama causado pela indução entre as antenas e o WOW
Fonte: Xavier Neto (2006)

O *WOW* é um componente transiente de baixa frequência, que contamina o registro do GPR e aparece como uma zona “enevoad” no radargrama - Figura 6.11.

6.4.5. CONFIGURAÇÃO DAS ANTENAS

Fracasso (2005) enfatiza que as antenas devem ser mantidas separadas a uma mesma distância que o comprimento de onda que a antena utiliza. Por exemplo: 1 m para 100 MHz e 10 cm para 1000 MHz. As antenas colocadas juntas uma da outra minimizam distorções próximas à superfície. Entretanto, podem resultar em interferências entre elas.

As antenas são orientadas horizontalmente sobre o solo, de modo a maximizar o acoplamento. Na direção *inline* as antenas Tx (emite sinal) e Rx (recebe sinal) estão com o *offset* paralelo ao perfil. Na direção *crossline*, as antenas Tx e Rx estão com *offset* perpendicular ao perfil. Há 4 orientações possíveis para o par de antenas: 2 *inline* e 2 *crossline*.

A Figura 6.12 apresenta as possíveis orientações. A linha tracejada representa o caminhamento e os retângulos representam as antenas. O sinal emitido é representado pela letra *S* e o sinal refletido (recebido) está representado pela letra *R*.




Figura 6.12 - Possíveis orientações das antenas
Fonte: Annan (1992)

A configuração das antenas é fator que determina o que pode ser visto em uma seção com o uso do GPR. Observa-se na Figura 6.13 as quatro possíveis orientações e as mudanças (sutis) nas imagens.




Figura 6.13 - Mudanças na imagem devido à configuração das antenas
Fonte: Annan (1992)

Até agora, descreveu-se basicamente, sobre a aquisição de dados e procedimentos para coletá-los. Na próxima seção, será abordado o processamento dos dados GPR.

6.5. PROCESSAMENTO DOS DADOS

É possível, muitas vezes, interpretar as imagens brutas no próprio local de aquisição, desde que essas se apresentem suficientemente claras. Em outras situações, quando a imagem bruta não é boa, aplicam-se técnicas de processamento de dados, para a recuperação do sinal perdido durante o trajeto da onda e melhorando a relação sinal/ruído, produzindo imagens de mais fácil interpretação.

O processamento dos dados do radar pode ser *básico* ou *avançado* e, independente de um ou de outro, geralmente seguem os seguintes passos: a) pré-processamento; b) conversão dos dados para um formato digital utilizável; c) remoção das ondas direta e aérea; d) aplicação de ganhos; e) correção estática; f) filtragem espacial e temporal; g) análise de velocidade; h) deconvolução do pulso; i) migração (DOURADO, 2004).

O pré-processamento é para eliminar ou minimizar ruídos grosseiros (ruídos provenientes da rede elétrica, reflexões de superfície de corpos metálicos, etc) ou até mesmo um tipo de reflexão indesejada vindo da subsuperfície.

A aplicação de ganhos aos dados é através de funções (lineares ou exponenciais), com o intuito de compensar perdas de amplitude na imagem do radar, uma vez que os sinais mais superficiais têm maior amplitude que os sinais mais profundos, devido à divergência esférica e a atenuação do próprio meio onde o sinal se propaga.

A correção estática dos dados representa o ajuste de tempo nulo com a profundidade nula, sendo também necessária quando o terreno apresenta uma topografia irregular (os traços do radargrama apresentam níveis diferentes, apresentando distorções nas interfaces subjacentes).

A filtragem dos dados é porque, muito embora o sinal GPR seja emitido e recebido com frequência específica, o registro do sinal inclui uma banda de frequência ao redor da frequência dominante. Utiliza-se um filtro de frequência (passa banda, passa alta ou passa baixa), através da análise do espectro da amplitude dos dados, detectando a frequência que se queira eliminar, de forma a se obter uma imagem mais limpa e de fácil interpretação.

A análise de velocidade do pulso é uma das etapas mais importante do processamento de dados e consiste em determinar as velocidades em subsuperfície a partir dos dados registrados.

A deconvolução do pulso opera tentando remover o efeito da *Wavelet* fonte (os pulsos do GPR são definidos no domínio do tempo), no intuito de melhorar as imagens. No entanto, essa operação pode degradar a imagem, pois no caso de radar, a assinatura da fonte não é bem definida.

A migração é um processo para corrigir a posição da interface que aparece no radargrama, tentando eliminar os efeitos associados à propagação da frente de onda na subsuperfície.

6.5.1. PROCESSAMENTO BÁSICO

Segundo Dourado (2004), o processamento básico traz uma melhoria da qualidade da imagem em relação à imagem bruta. Nesse processamento, há uma distinção de etapas a vencer em função do tipo de aquisição de dados.

(i) Na aquisição de dados mono-estáticas

As etapas são: a) correção estática; b) subtração do ponto médio; c) normalização horizontal; d) aplicação de ganhos.

A subtração do ponto médio visa remover a interferência dos dados devido à proximidade das antenas de transmissão e recepção.

A normalização horizontal é para remover o efeito do movimento não

constante de aquisição dos dados ao longo do perfil.

As outras etapas já foram explicadas na subseção 6.4.6.

(ii) Na aquisição de dados bi-estáticas

As etapas são - todas já explicadas na seção 6.4.6 e subseção 6.4.6.1(i): a) correção estática; b) filtragem; c) velocidade de propagação de pulso (somente para o arranjo CMP); d) aplicação de ganhos.

6.5.2. PROCESSAMENTO AVANÇADO

Ainda, segundo Dourado (2004), o *processamento avançado* é utilizado com a intenção de melhorar ainda mais a qualidade da imagem, obtida no processamento básico.

As etapas do processamento avançado, independente do modo de aquisição de dados ser mono-estático ou bi-estático, são: a) média lateral; b) filtragem; c) deconvolução; d) migração.

Já as etapas de análise de velocidade, correção NMO (*Normal Moveout*) e empilhamento (*stack*), são exclusivas para o modo de aquisição bi-estático.

A correção NMO é uma correção geométrica dos dados de reflexão presentes numa família CMP, de modo que dados com afastamentos não nulos entre transmissor e receptor (com diferentes tempos de propagação), depois de corrigidos, se alinhem no tempo correspondente ao de afastamento nulo. As outras etapas já foram explicadas anteriormente.

A Figura 6.14 apresenta um resumo das etapas explicadas nessa seção.




Figura 6.14 - Etapas do processamento de dados GPR

Até aqui se fez uma apresentação sobre o uso do GPR e o processamento dos dados de campo. A seção seguinte aborda a metodologia utilizada na análise automática da determinação das camadas do pavimento com o uso dos radargramas.

6.6. MATERIAIS E MÉTODOS

Nesta seção pretende-se apresentar um experimento, que foi desenvolvido com o intuito de determinar automaticamente as camadas do pavimento com o uso dos radargramas, através da análise de textura, utilizando técnica de reconhecimento automático de padrões.

6.6.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O experimento ocorreu na pista sul da Via Dutra, no município de Pirai (RJ). Trata-se de um trecho de reconstrução do pavimento, no km 239+760, faixa 2 (faixa externa), em um total de dois perfis, sendo um no sentido

longitudinal da pista e um transversalmente ao acostamento - veja Figura 6.15. Esse local foi escolhido devido poder-se identificar visualmente tanto as camadas do pavimento quanto suas respectivas espessuras. A data do experimento foi dia 5 de junho de 2009.



Figura 6.15 - Trecho do experimento - pista sul da via Dutra (RJ)

6.6.2. MATERIAL

Usou-se um GPR de arraste (contato), da marca GSSI, modelo SIR-3000, com uma antena blindada de 900 MHz e modo de aquisição de dados mono-estático, pois as antenas estão acondicionadas em um único módulo, mantendo a distância entre elas sempre constante.

Esse equipamento possui além das antenas, uma unidade de controle, um hodômetro para registrar o comprimento dos perfis e um bastão com punho para auxiliar no arraste das antenas - Figura 6.16.



Figura 6.16 - Equipamento GPR utilizado no experimento

Outros itens utilizados no experimento foram: GPS de navegação, trena de 5m, câmera fotográfica, prancheta, etc.

6.6.3. OBTENÇÃO DOS DADOS DE CAMPO

O trabalho de campo é relativamente simples. Inicialmente, devem-se definir os parâmetros que se serão utilizados para as medições com o GPR. Após, faz-se uma calibração do hodômetro para, finalmente, percorrer o trecho onde se pretende obter o perfil da subsuperfície, arrastando as antenas.

6.6.3.1. DEFINIÇÃO DOS PARÂMETROS

Para o levantamento dos perfis da subsuperfície do pavimento e com a antena de 900 MHz, foram definidos os parâmetros no *menu* da unidade de controle, citando, por exemplo: a) dados do radar - frequência, modo de aquisição, etc; b) aquisição dos dados - formato dos dados, tempo de aquisição, etc, e c) unidades - de distância e profundidade.

6.6.3.2. CALIBRAÇÃO DO HODÔMETRO

Para a calibração do hodômetro faz-se uma marca no chão e outra a 20 m de distância. Posicionam-se as antenas no início do trecho e arrasta-as até o final do trecho. Em seguida informa ao equipamento que percorreu uma distância de 20m. A calibração está concluída.

6.6.3.3. LEVANTAMENTO DOS PERFIS SUBSUPERFICIAIS

Levantaram-se 2 perfis, ambos utilizando o mesmo procedimento. Posicionam-se as antenas no início do perfil, arrasta-as até o final e, em seguida, nomeia-se o arquivo daquele perfil.

6.6.3.4. PROCESSAMENTO DOS DADOS

Os dados de campo dos dois perfis subsuperficiais levantados foram processados no *software* GRADIX, da empresa Interpex Limited, cuja sequência de operação encontra-se no Apêndice C.

Após o processamento obteve-se o radargrama dos dois perfis sub-superficiais, conforme Figura 6.17.

NOME	DESCRIÇÃO	IMAGEM
Imagem 1	Perfil localizado a 30cm do bordo da reconstrução da pista - comprimento de 25m	
Imagem 2	Perfil localizado a 30cm do bordo da reconstrução do acostamento - comprimento de 5,5m	

Figura 6.17 - Radargrama dos dois perfis levantados

6.6.4. METODOLOGIA DO TRABALHO

Para a discriminação das camadas do radargrama através da análise de textura utilizou-se a mesma metodologia descrita na subseção 5.6.4.1.

Inicialmente, as classes informacionais a serem discriminadas nas imagens do radargrama, para as duas imagens, foram: a) revestimento; b) base; c) sub-base; d) subleito. Essas classes foram identificadas no local e estão apresentadas na Figura 6.18.


DESCRIÇÃO	IMAGEM
Vista do corte no pavimento - sentido longitudinal, com a identificação das camadas (válido para a Imagem 1)	

Figura 6.18 - Identificação das classes informacionais do pavimento


DESCRIÇÃO	IMAGEM
Vista do corte no acostamento - sentido longitudinal, com a identificação das camadas (válido para a Imagem 2)	

Figura 6.18 - Identificação das classes informacionais do pavimento (cont.)

Posteriormente, analisando os radargramas das duas imagens verificou-se que visualmente só se conseguia distinguir três camadas. Assim, as imagens serão analisadas com três classes: a) camada 1 – revestimento; b) camada 2 – base e sub-base; c) camada 3 – subleito.

Utilizaram-se apenas blocos 4x4 *pixels*, visto que blocos maiores (8x8 e 16x16) não deram resultados satisfatórios, conforme relatado na subseção 5.6.4.1.

Com os vetores de características extraídos do radargrama passou-se a fase da classificação supervisionada, utilizando-se inicialmente o algoritmo MaxVer e, posteriormente, usando RNA.

Tanto para a classificação MaxVer e RNA foram selecionadas amostras independentes, divididas em amostras de treinamento e amostras de teste, respectivamente. Para compor as amostras de treinamento foram extraídas 80 amostras para cada classe. Já para as amostras de teste selecionou-se exatamente a metade, ou seja, 40 amostras por classe.

Para facilitar a extração das amostras independentes fez-se uma envoltória nas camadas – Figura 6.19, evitando adquirir amostras em camadas erradas. Tratando-se de radargrama, esse procedimento é importante, visto que a imagem é muito longa e, às vezes, confunde o examinador.




Figura 6.19 – Separação das camadas do radargrama para facilitar a obtenção das amostras independentes

Usou-se a rotina desenvolvida no *software* MatLab para facilitar a extração das amostras independentes (blocos) e a determinação dos vetores de características respectivos, por classe considerada (Apêndice B).

Para a modelagem da RNA, inicialmente, re-escalou-se os dados entre 0 e 1, para evitar saturação na rede no início do treinamento. A definição da topologia interna da rede seguiu o procedimento descrito por Hirose *et al.* (1991). Os outros parâmetros da rede ficaram assim definidos: os pesos iniciais foram gerados aleatoriamente variando de -0,3 a 0,3; utilizou-se função de ativação logística e taxa de aprendizagem 0,2 e *momentum* com valor fixo de 0,9; uso das funções de aprendizagem *Backpropagation* e *Backpropagation* com *Momentum*.

6.6.5. RESULTADOS E DISCUSSÕES

Os resultados da classificação das 120 amostras de teste independentes, com o uso do algoritmo MaxVer estão apresentados na Tabela 6.3.

Tabela 6.3 – Resultados da classificação MaxVer

IMAGEM	MATRIZ DE ERROS						PARÂMETROS
Imagem 1	Classe	1	2	3	Total	E.C.(%)	Kappa = 0,312
	1	36	19	17	72	50,0	Var. Kappa = 0,003374
	2	3	6	0	9	33,3	Z estatístico = 5,380
	3	1	15	23	39	41,0	
	Total	40	40	40	120		EG = 54,2%
	E.O.(%)	10,0	85,0	22,5			

Tabela 6.3 – Resultados da classificação MaxVer (cont.)

IMAGEM	MATRIZ DE ERROS						PARÂMETROS
Imagem 2	Classe	1	2	3	Total	E.C.(%)	Kappa = 0,438
	1	25	24	1	50	50,0	Var. Kappa = 0,003829
	2	8	11	0	18	42,1	Z estatístico=7,07
	3	7	5	39	51	23,5	
	Total	40	40	40	120		EG = 62,5%
	E.O.(%)	37,5	72,5	2,5			

Onde: E.C. - erro de comissão e E.O. - erro de omissão; Classe 1 - camada 1 (revestimento); Classe 2 - camada 2 (base + sub-base); Classe 3 - camada 3 (subleito).

Em relação a classificação das 120 amostras de teste independentes, utilizando RNA, os resultados estão apresentados na Tabela 6.4.

Tabela 6.4 - Resultados da classificação RNA

IMAGEM	MATRIZ DE ERROS						PARÂMETROS
Imagem 1	Classe	1	2	3	Total	E.C.(%)	Kappa = 0,388
	1	20	9	0	29	31,0	Var. Kappa = 0,004121
	2	7	17	6	30	43,3	Z estatístico = 6,036
	3	13	14	34	61	44,3	
	Total	40	40	40	120		EG = 59,2%
	E.O.(%)	50,0	57,5	15,0			
Imagem 2	Classe	1	2	3	Total	E.C.(%)	Kappa = 0,613
	1	26	9	0	35	74,3	Var. Kappa = 0,003431
	2	11	23	0	34	67,6	Z estatístico = 10,457
	3	3	8	40	51	78,4	
	Total	40	40	0	120		EG = 74,2%
	E.O.(%)	35,0	42,5	0			

Onde: E.C. - erro de comissão e E.O. - erro de omissão; Classe 1 - camada 1 (revestimento); Classe 2 - camada 2 (base + sub-base); Classe 3 - camada 3 (subleito).

O erro de omissão é o erro devido a *pixels* classificados omitidos de sua correta classe e assinalados a uma outra classe, e o erro de comissão é o erro devido a *pixels* que são erroneamente incluídos em uma dada classe quando

deveriam ser assinalados à classe correta.

O índice Kappa e a sua variância representam uma ponderação entre as concordâncias e discrepâncias dos dados de referência e os dados classificados. Com o índice Kappa e sua variância é possível aplicar o teste estatístico Z, que sendo maior que o valor tabelado de 1,96, é significativo para 95% dos níveis de confiança, sendo considerado melhor que uma classificação aleatória.

A Imagem 1, quando classificada pelo MaxVer, obteve uma exatidão global igual a 54,2% e um Kappa igual a 0,312. Já a Imagem 2 obteve para o mesmo classificador, uma exatidão global igual a 62,5% e um Kappa igual a 0,438.

Quando se classificaram as imagens com RNA, a Imagem 1 obteve uma exatidão global igual a 59,2% e um Kappa igual a 0,388. Já a Imagem 2 obteve para o mesmo classificador, uma exatidão global igual a 74,2% e um Kappa igual a 0,613.

A topologia da RNA utilizada na Imagem 1 foi 2-3-3 (2 neurônios na camada de entrada, 3 neurônios na camada escondida e 3 neurônios na camada de saída) e a rede estabilizou-se com 10.000 ciclos. Já para a Imagem 2, a topologia foi 2-8-3 e a rede estabilizou-se com 25.000 ciclos.

Considerando a qualidade do radargrama para as duas imagens analisadas, tanto os dados classificados pelo MaxVer quanto pela RNA apresentaram resultados aceitáveis. A Imagem 2 foi melhor classificada que a Imagem 1, tanto com o classificador MaxVer quanto com RNA, possivelmente porque as amostras da Imagem 2 foram mais representativas das camadas consideradas. Uma vez que as imagens analisadas são muito parecidas, esperava-se resultados semelhantes.

Ambos os classificadores tiveram dificuldades em distinguir a Classe 2, confundindo, principalmente, com a Classe 1. A Classe 3 foi a melhor

classificada pelos dois classificadores.

Esclarecendo sobre a qualidade do radargrama citado anteriormente, na prática mundial rodoviária, utiliza-se GPR de frequência superior a 1,6 GHz, que proporciona uma qualidade do radargrama bem superior ao utilizado nesta tese, obtido com um GPR de 900 MHz.

6.6.6. CONCLUSÕES

Este experimento teve como objetivo analisar a possibilidade de identificar as camadas de um pavimento, através do radargrama e utilizando técnicas estatísticas de reconhecimento de padrões e redes neurais artificiais (RNA). Baseados nos testes desenvolvidos apresentam-se as seguintes conclusões.

A metodologia de particionar a imagem em blocos, aplicando em seguida a Transformada *Wavelet* e o conjunto dos extratores (ICW e média do brilho) para definir o vetor de característica dos blocos, mostraram-se razoavelmente eficiente na classificação supervisionada dos dois radargramas analisados, considerando a qualidade do radargrama, difícil até de fazer a interpretação visual.

O teste estatístico Z comprovou que a classificação foi significativamente melhor do que uma classificação aleatória. A Imagem 2 foi melhor classificada que a Imagem 1 em ambos os classificadores.

A RNA, de uma maneira geral, classificou melhor as imagens do que o MaxVer, mostrando o potencial desse algoritmo. Quanto aos extratores utilizados (ICW e média dos brilhos), formaram um par de valores que representaram razoavelmente bem as características das imagens analisadas.

Acredita-se que se os radargramas das Imagens 1 e 2 fossem obtidos com um GPR de frequência superior a 1,6 GHz, os resultados do experimento seriam bem superiores, devido à melhoria significativa da qualidade do radargrama.

6.7. RESUMO DO CAPÍTULO

Como resumo desse capítulo, abordou-se a textura para discriminar as camadas do pavimento, através dos radargramas, obtidos com um GPR de 900 MHz, adotando a mesma metodologia do Capítulo 5 (seção 5.6.4).

Os resultados obtidos não foram tão bons quando comparados com os resultados do Capítulo 5 (seção 5.6.4). No entanto, há de se atentar que a frequência do GPR utilizado é considerada baixa para a aplicação em pavimentos rodoviários.

CAPITULO 7

SISTEMA DE GERÊNCIA DE PAVIMENTO

Nesse capítulo abordam-se aspectos gerais da gerência de pavimentos no Brasil: histórico, o que é, para que serve, vantagens, etc. Em seguida, são apresentados os procedimentos para entrada de dados no HDM-4. Para encerrar, fez-se uma análise do uso dos dados obtidos na classificação das imagens digitais do pavimento, descritos nos Capítulos 4, 5 e 6, no HDM-4.

7.1. INTRODUÇÃO

Segundo Queiroz (1984), no Brasil, até 1960, atividades de conservação rodoviária, além de praticamente não existirem, ainda apresentavam o agravante de não seguirem um planejamento. Com a crescente dependência do país em relação ao modal rodoviário, ocorreu uma mudança de postura e, desde então, a conservação passou a ser vista como uma atividade tão importante quanto construir.

A partir de 1980, alguns fatores estimularam os órgãos rodoviários a utilizar um SGP que, como consequência, acabou tornando-se uma ferramenta de fortalecimento institucional de cada órgão. São eles: a) maior evidência da necessidade de manutenção oportuna e adequada em virtude do envelhecimento dos pavimentos; b) a exiguidade dos recursos; c) o efeito direto da condição do pavimento e os custos operacionais dos veículos (manutenção, consumo de pneu e combustível); d) as exigências de órgãos financiadores, mais especificamente o Banco Internacional para a Reconstrução e o Desenvolvimento (BIRD) e o Banco Interamericano de Desenvolvimento (BID), que passaram a estimular o emprego de técnicas racionais, visando melhores resultados na aplicação dos recursos; e) a substituição de procedimentos arcaicos por tecnologias avançadas, para a avaliação de pavimentos (equipamentos e métodos).

Com os programas rodoviários desenvolvidos, os órgãos brasileiros

solicitavam ao BID ou ao BIRD recursos para atender ao que havia sido planejado.

Quanto aos modernos equipamentos, podem-se citar aqueles voltados para a medição da irregularidade, como os vários tipos de perfilômetros disponíveis no mercado, principalmente aquele que utiliza o sensor *laser*, que dá uma altíssima produção no levantamento dessa atividade. Já para o cálculo da retro-análise tem-se um valioso auxiliar, que é o equipamento GPR – obtém no campo informações sobre as camadas do pavimento (espessura e densidade), através da sísmica de reflexão. Com respeito à aderência pneu-pavimento, tem-se, por exemplo, os equipamentos rebocáveis que medem o coeficiente de atrito dinâmico: o *me-meter* e o *griptester*.

A Figura 7.1. apresenta em (a) o *me-meter*, em (b) o *griptester* e em (c) um perfilômetro a *laser*.




Figura 7.1 – Equipamentos modernos utilizados em rodovia para medir a aderência e a irregularidade

Fonte: (a) – Me-meter MK6 (Foto: <http://www.airport-technology.com> (26/06/2009)); (b) – GripTester (Foto: <http://www.inec.pt> (02/06/2008)); (c) – Perfilômetro a *laser* (Foto: <http://www.cibermetrica.com.br> (02/06/2008))

Quanto aos novos métodos, esses são baseados em novas equações de custos operacionais de veículos e novos modelos de desempenho de pavimentos, ambos desenvolvidos para atenderem à realidade brasileira atual.

Alguns sistemas foram criados com a finalidade de auxiliar os programas de investimentos: a) Sistema de Informações Básicas (SIB) – abordando o monitoramento da malha rodoviária, com dados sobre o trânsito e avaliação funcional/estrutural do pavimento; b) Sistema de Administração da Manutenção (SAM) – voltado para o planejamento da conservação de rotina; c)

Sistema de Administração da Conservação (SAC) – voltado para o planejamento de manutenções e priorizações de ações de conservação.

A Tabela 7.1. apresenta informações sobre sistemas de gerência, órgão financiador e algumas informações relevantes sobre o uso do sistema de gerência, utilizados em determinados estados brasileiros e, também, no DNIT. Por exemplo, em Minas Gerais, a gerência de pavimento das rodovias sob concessão estadual vem sendo feita desde a década de 1980, através de monitoramento descontínuos e o sistema de gerência utilizado para análise e planejamento é o HDM, cujas intervenções foram financiadas pelo BIRD.

Tabela 7.1 – Informações sobre sistemas utilizados em alguns estados/órgão brasileiros
Fonte: www.andit.org.br/assets/SGPHD.pdf (10/02/2009)

Estado/ Órgão	Financia- mento	Sistema de Gerência	Informações relevantes sobre o sistema de gerência
MG	BIRD	SGP com HDM	Desde a década de 1980 Monitoramento descontínuo
SP	BID		Monitoramento recente
PR		SAM/SGP	Desde a década de 1980 Programa de SGP bem estruturado Muitos anos sem monitoramento Abandonado
SC	BID	SAM/SGP	Desde a década de 1980 Monitoramento constante Modelo francês
RS	BIRD/BID		Monitoramento 2000/2002 Adquiriu equipamentos para monitoramento
ES	BID		Década de 1990 Sem continuidade
BA	BID	SIB/SAM/SGP	Década de 1990 Só um monitoramento completo em 1995/1996 Atualmente prioriza SIB e SAM Atualiza o LVC anualmente, com equipes próprias Fazendo cadastro para o SAM Modernizando BD
GO	BIRD	SIB e SGP	Monitoramento 2000
PE	BID	SIB/SAM/SGP	Década de 1990 Só um monitoramento Sem continuidade
AL	SGP similar ao modelo de SC		Banco de dados bem estruturado

**Tabela 7.1 – Informações sobre sistemas utilizados em
alguns estados/órgão brasileiros (cont.)**
Fonte: www.andit.org.br/assets/SGPHD.pdf (10/02/2009)

Estado/ Órgão	Financia- mento	Sistema de Gerência	Informações relevantes sobre o sistema de gerência
CE	BID	SIB/SAC/SGP	Primeiro monitoramento (2001) – LVC, IRI, deflexões 2002 – LVC e IRI 2003 – LVC e IRI
DNIT	BIRD/BID	SGP	Monitoramento de toda rede 2002/2004 – LVC, IRI, deflexões com FWD

Onde: LVC - levantamento visual contínuo; IRI - índice de irregularidade internacional; FWD (*Falling Weight Deflectometer*) - dispositivo para a determinação das deflexões do pavimento.

7.2. REVISÃO DA LITERATURA

Nessa seção fez-se uma revisão da literatura, citando trabalhos brasileiros que abordaram a gerência de pavimentos.

Lerch (2002) analisou, em pavimentos recapeados, a evolução da irregularidade longitudinal de pavimentos, em cerca de 265 km de vias representativas da malha do Estado do Rio Grande do Sul. Registrou irregularidades antes e após o recapeamento, e as reduções medidas foram comparadas com valores previstos pelos modelos linear e bilinear propostos pelo programa HDM-4. Concluiu que as diferenças entre reduções previstas e medidas alertaram para a necessidade de ajuste dos modelos em alguns casos, levando em conta as estruturas dos pavimentos e as espessuras de recapeamentos analisadas, propondo valores para os parâmetros ajustáveis dos modelos, cuja aplicação minimizaram as diferenças entre as reduções medidas e previstas.

Nunes (2003) apresenta o resultado de uma pesquisa experimental, desenvolvendo um método, com auxílio de redes neurais artificiais, para a previsão de defeitos em estradas vicinais de terra. No método, buscou analisar a previsão dos defeitos e respectivas severidades, para subsidiar as atividades de um sistema de gerência de vias, possibilitando analisar as

intervenções necessárias de acordo com a melhor alocação de recursos financeiros disponíveis.

Campos (2004) analisou seções de pavimento flexível, ao longo de 98 quilômetros da malha rodoviária do estado de São Paulo, fazendo a comparação de resultados entre 4 importantes modelos de previsão de desempenho funcional de pavimentos (DNER PRO 159/85, HDM III, HDM 4 e o modelo mecanístico proposto por SALEH, MAMLOUK e OWUSU-ANTWI), entre si e com os dados de irregularidade longitudinal levantados com medidor tipo resposta. A partir dos resultados propôs ajustes aos modelos de modo a compatibilizar as estimativas dos modelos com os resultados reais obtidos em campo.

Klein (2005), utilizando o HDM-4, verificou e analisou a influência das características geométricas de trechos de rodovia no custo total dos usuários, em termos de custo de operação dos veículos e custo do tempo de viagem. Desenvolveu um estudo de caso para várias situações consideradas pelo HDM-4, em um total de 30 trechos com distintas características geométricas. O autor concluiu que a geometria pode ter grande influência no custo total dos usuários, devendo ser considerado em projetos de construção e de manutenção de rodovias.

Machado *et al.* (2005) abordaram o sistema de gerência de pavimentos de estradas florestais. Informam que a extensão da malha rodoviária florestal é da ordem de 600 mil quilômetros, com tendência crescente devido às ampliações de áreas plantadas das empresas florestais e que, nos últimos anos, as exigências em termos de solicitações dessas estradas vêm aumentando. Citam que a utilização de SGPs vem crescendo no Brasil nas últimas décadas, com trabalhos voltados para várias atividades rodoviárias.

Marques (2005) propõe uma metodologia para o gerenciamento de rodovias de baixo volume de tráfego, consistindo o SGP dos seguintes módulos: coleta de dados, base de dados, avaliação de desempenho e das condições da rede e retro-alimentação. No *software* EXCEL, desenvolveu os

modelos de deterioração baseado em Paterson (1987) e que foram aplicados no acompanhamento das condições da rodovia e programação dos investimentos.

Nakahara (2005), com base em dados levantados em campo e em projetos de restauração anteriormente realizados, desenvolveu modelos empíricos de previsão de desempenho dos reforços de pavimentos asfálticos, levando em consideração fatores relevantes para seu comportamento. Para isso, testou modelos lineares com diferentes estruturas de covariância e também modelos de regressão logística e concluiu que os modelos mostraram-se mais conservadores que aqueles empregados na previsão de desempenho do programa HDM-4, para as condições do problema, no que concerne à evolução do trincamento. No caso de previsão de irregularidade, observou resultados similares entre os modelos desenvolvidos e aqueles preconizados pelo programa HDM-4.

Nascimento (2005) comparou modelos de desempenho de pavimentos, desenvolvidos por pesquisadores e órgãos rodoviários brasileiros e internacionais, além do modelo de deterioração do HDM-4. Comparou o desempenho real de seções de pavimentos rodoviários, obtido a partir da base de dados dos experimentos *Long-Term Pavement Performance* (LTPP) do *Federal Highway Administration* (FHWA) com o comportamento previsto pelos modelos de Queiroz, Paterson, Marcon e Yshiba. Para tanto, utilizou uma programação fatorial que, utilizando a análise de variância, permite a determinação do nível de significância de fatores pré-selecionados, bem como a modelagem do desempenho dos pavimentos das seções analisadas.

Yshiba e Fernandes Júnior (2005) desenvolveram modelos estatísticos para previsão do desempenho de pavimentos baseados em séries históricas de dados, estabelecendo equações de regressão através de Análise de Variância. Citam os autores que os modelos de desempenho desenvolvidos por eles apresentam melhores resultados quando comparados com equações desenvolvidas por pesquisadores e órgãos rodoviários brasileiros e estrangeiros.

Azevedo (2007) realizou análise de sensibilidade dos modelos da AASHTO (versão 1993) e HDM-4. Os modelos empregam coeficientes de drenagem para a consideração dos efeitos danosos da presença de água livre no interior de estruturas de pavimentos rígidos e flexíveis. Verificou-se que os modelos são sensíveis quanto à influência das condições de drenagem no desempenho dos pavimentos. Analisou dados reais de certa malha viária no interior do estado de São Paulo e verificou que os pavimentos flexíveis sem acostamento pavimentado têm apresentado desempenho inferior quando comparados com estruturas dotadas de acostamentos pavimentados. Constatou a dificuldade de se adotar os coeficientes de drenagem nos modelos analisados, apesar da grande importância da fixação adequada no dimensionamento, sugerindo procedimentos para o dimensionamento hidráulico do sistema de drenagem de pavimentos e a necessidade de se considerar a avaliação econômica ao longo de um período, de acordo com o desempenho esperado do pavimento.

Lima (2007) propõe um modelo destinado a auxiliar administradores de órgãos governamentais na priorização de intervenções de vias urbanas pavimentadas, baseado na metodologia de análises multicritério agregada a um Sistema de Informações Geográficas (SIG), no apoio à tomada de decisões. Para tanto, realizou um estudo de caso na cidade de São Carlos (SP), utilizando um levantamento preliminar das condições do pavimento e de suas características geométricas, de responsabilidade da prefeitura da cidade.

Esta revisão bibliográfica teve como objetivo mostrar, através das literaturas citadas, o qual imprescindível tornou-se para o Brasil o uso de sistemas de gerência de pavimento na área rodoviária. Cada padrão de via e cada categoria de usuários exige estradas com características diferentes e com métodos de avaliação compatíveis, evidenciando a importância desses sistemas.

7.3. SISTEMA DE GERÊNCIA DE PAVIMENTO

Sistema é um conjunto de componentes que interagem mutuamente,

afetados por fatores externos (FERREIRA, 2009). Por exemplo, em um Sistema de Gerência de Pavimento (SGP), os componentes normalmente são: o planejamento, o projeto, a construção e a manutenção. Já os fatores externos são: os recursos orçamentários, os dados necessários ao sistema e as diretrizes políticas e administrativas.

SGP é o termo utilizado para descrever o conjunto de ações relacionadas à seleção e priorização das atividades de manutenção e reabilitação de pavimentos, visando a obter o melhor retorno possível para os recursos investidos, fornecendo pavimentos seguros, confortáveis e econômicos para os usuários.

O uso de um SGP é mais indicado quanto menor for a disponibilidade financeira e pior as condições em que se encontrar o pavimento, pois um SGP tem por principal objetivo alcançar a melhor aplicação possível para os recursos disponíveis e oferecer um transporte rodoviário seguro e econômico.

7.3.1. NÍVEIS DE GERÊNCIA DE UM SGP

Um SGP normalmente é dividido em 2 níveis de gerência: gerência ao nível de rede e gerência ao nível de projeto, conforme a Figura 7.2.




Figura 7.2 - Níveis de gerência de um SGP
Fonte: adaptado de Hass et al. (1994)

7.3.1.1. GERÊNCIA EM NÍVEL DE REDE

Na gerência ao nível de rede as informações são baseadas nos dados de campo coletados e não há detalhamento do projeto. Nessa fase, indicam-se os trechos prioritários da malha rodoviária que devem ser objetos de investimentos, cujo principal objetivo é permitir a elaboração de um programa pluri-anual de investimentos.

Aqui, são indicadas para cada trecho da malha analisada, a alternativa de manutenção ideal e a época em que se deve proceder ao investimento para que os recursos tenham o melhor retorno econômico.

As etapas que compõem essa fase são: programação, planejamento e orçamento.

7.3.1.2. GERÊNCIA EM NÍVEL DE PROJETO

Na gerência ao nível de projeto há o envolvimento de atividades detalhadas de projetos, tais como o dimensionamento, a construção, a manutenção e a reabilitação, além da execução de obras em um trecho específico da rede.

Nas atividades da gerência ao nível de projeto as recomendações da gerência ao nível de rede devem ser confirmadas e detalhadas, subsidiando orçamentos e programas de curto prazo.

7.3.2. COMPONENTES PRINCIPAIS DE UM SGP

Um *software* para ser considerado um SGP deve ter, pelo menos, os seguintes itens contemplados: base de dados, avaliação de pavimento, previsão de desempenho de pavimento, critério de decisão, análise técnica e análise econômica. Estes itens são detalhados nas subseções seguintes.

7.3.2.1. BASE DE DADOS

Os dados coletados, e que servirão para alimentar o sistema, são a

parte essencial para análise. Mesmo tendo-se um SGP com excelentes modelos incorporados, se os dados não forem confiáveis (total ou parcialmente), seus resultados possivelmente serão duvidosos.

Como características gerais, os dados devem ser compreensíveis, confiáveis, de fácil obtenção e baixo custo.

As principais classes de dados são: a) relacionadas ao desempenho do pavimento - irregularidade, aderência, propriedades mecânicas dos materiais das camadas, defeitos de superfície e medidas deflectométricas; b) relacionados ao histórico da via - construção, manutenção, trânsito e acidentes; c) custos - construção, manutenção, reabilitação e transporte (usuário); d) geometria - seção transversal, tangentes, curvas e greide; e) meio ambiente - clima e drenagem.

7.3.2.2. AVALIAÇÃO DE PAVIMENTO

As avaliações, tanto estrutural quanto funcional, são uma parte essencial de um SGP, visto que a partir delas é que se estabelecem os modelos de previsão de desempenho, além da definição das estratégias de manutenção.

O entendimento dos mecanismos que determinam o processo de deterioração do pavimento está ligado à identificação das causas que levam o pavimento à mudança de suas condições iniciais.

De acordo com Domingues *et al.* (1996), a coleta de dados relativa ao acompanhamento do estado de conservação de um pavimento, aliado às características históricas, gera um banco de dados para ser empregado em um sistema de avaliação e gerência de pavimentos ao longo do tempo.

7.3.2.3. MODELOS DE PREVISÃO DE DESEMPENHO

Esses modelos são uma descrição matemática para prever, em função

do estado atual do pavimento, a evolução de um determinado defeito ao longo de um período de análise determinado. Esses modelos são desenvolvidos em função dos dados extraídos do pavimento, confirmando, mais uma vez, a importância de uma base de dados.

A tomada de decisão em um SGP depende, dentre outros fatores, da estimativa da evolução da condição do pavimento ao longo do tempo. Tal estimativa é obtida por uma função que relaciona as causas com os efeitos da deterioração dos pavimentos, denominada “Modelos de Desempenho” (YSHIBA e FERNANDES, 2005).

Os modelos de previsão de desempenho são utilizados para estimar a evolução da condição do pavimento ao longo do tempo, considerando geralmente fatores como: idade, tráfego, clima e número estrutural. Devem retratar, da melhor forma possível, as condições locais, com base nos dados coletados e na experiência com os pavimentos locais, uma vez que cada região apresenta características distintas.

Em relação aos tipos de modelos de desempenho, Hass *et al.* (1994) propõem classificá-los segundo quatro classes: a) modelos mecanísticos; b) modelos empírico-mecanístico; c) modelos empíricos ou de regressão; d) modelos probabilísticos (ou subjetivos).

Modelos mecanísticos são modelos baseados em parâmetros de respostas estruturais, como: tensão, deformação ou deslocamento.

Modelos empírico-mecanísticos são modelos que utilizam respostas estruturais do pavimento (tensão, deformação ou deslocamento) e que são relacionados com a deterioração funcional ou estrutural.

Modelos empíricos ou de regressão são modelos em que as variáveis

dependentes, relativas à deterioração funcional ou estrutural, são relacionadas a uma ou mais variáveis independentes, como: suporte do subleito, aplicações de carga por eixo, propriedades e espessuras das camadas do pavimento, fatores ambientais, etc

Modelos probabilísticos são modelos em que a experiência de engenheiros é formalizada através de processos de transição, como, por exemplo, as Cadeias de Markov, que permite a obtenção de modelos de desempenho mesmo com uma pequena série histórica de dados.

A Tabela 7.2 apresenta alguns modelos de previsão de desempenho bastante conhecidos no meio rodoviário, inclusive, apontando algumas características relevantes. Observa-se que os modelos contemplam determinados defeitos, sendo seu desenvolvimento somente possível devido à base de dados disponível.

Tabela 7.2 - Modelos de previsão de desempenho

Nome do modelo	Contempla (previsão)	Características
Desenvolvido por Queiroz (1984)	irregularidade longitudinal trincamento pequenos remendos	os modelos foram desenvolvidos a partir da base de dados levantada para a Pesquisa sobre o Interrelacionamento dos Custos de Construção, Conservação e Utilização de Rodovias (PICR), iniciada em 1975 pela Empresa Brasileira de Planejamento de Transportes (GEIPOT)
Desenvolvido por Paterson (1987)	panelas desgastes trincamento total irregularidade longitudinal trilhas de roda	os modelos foram desenvolvidos a partir da base de dados levantada para a PICR e implementados nos <i>softwares</i> HDM-III e HDM-4

Tabela 7.2 - Modelos de previsão de desempenho (cont.)

Nome do modelo	Contempla (previsão)	Características
Desenvolvido por Marcon (1996)	QI deflexões máximas médias IGG trincamento total trilhas de roda	utilizando dados históricos de avaliações da malha rodoviária do Paraná, realizadas em 1995 e 1998, seus modelos representam os efeitos dos fatores idade, tráfego e número estrutural sobre o desempenho de pavimentos, relacionando-os com a irregularidade longitudinal e as deflexões recuperáveis
Desenvolvido por Yshiba (2003)	irregularidade longitudinal de pavimento reabilitado e não-reabilitado deflexão máxima recuperável de pavimento reabilitado e não-reabilitado	desenvolveu modelos onde foram estabelecidas equações de regressão tendo por base dados da malha rodoviária do Paraná, entre 1995 e 1998

7.3.2.4. CRITÉRIOS DE DECISÃO

Nesta seção serão abordados os critérios de decisão, sendo considerados como importantes características que um SGP deve contemplar.

Os critérios de decisão são limites definidos para os parâmetros de análise do pavimento e que, uma vez ultrapassado esses valores, indicam qual o tipo de atividade ou intervenção deve ser posta em ação. É uma tarefa complexa e com características peculiares à rodovia analisada, tais como, tipo de pavimento, classe da rodovia, etc.

A norma DNER-PRO 159/85 indica como limites típicos os seguintes valores para os parâmetros a seguir, obtidos no subtrecho homogêneo da via e que não deve ultrapassar 3.000 m: a) irregularidade = 50 a 70 contagens/km; b) trincamento (trincas tipo 1 e 2, incluindo buracos e remendos) = 15% a 40% em relação à área da superfície de avaliação; c) desgaste = 15% a 40% em relação à área da superfície de avaliação. Acima desses valores deverá ocorrer uma intervenção na via.

O HDM-4 utiliza como limite para intervenção na via o IRI, a *área total com defeitos* (ADAMS) - corresponde à soma das áreas de trincamento, de

desgaste e de buracos e a *área total de defeitos não-reparados* (ADAMR) - corresponde a soma das áreas de trincamento, buracos e desprendimento de agregado. Por exemplo, para a implementação da manutenção de rotina, associada ao reforço, os seguintes limites são utilizados: a) IRI /5 m/km e trincamento /15% - realiza-se o reforço; b) ADAMS > 5% - realiza-se a manutenção de rotina.

7.3.2.5. ANÁLISE TÉCNICA

A análise técnica do problema é uma característica local, ou seja, cada órgão de transporte deve estabelecer suas próprias alternativas, a partir da análise do histórico do pavimento de sua rede. As alternativas de análise técnica dependem de metodologias apropriadas que atendam problemas específicos do pavimento, usando estratégias de intervenção de manutenção ou reabilitação ao longo de um período, avaliando a resposta mecânica da estrutura, além do seu desempenho.

7.3.2.6. ANÁLISE ECONÔMICA

Análise econômica refere-se a ações para quantificar os impactos econômicos (benefícios e custos), determinar benefícios líquidos (benefícios menos custos) e distribuir esses impactos (incidência), podendo, também, incorporar recursos não-monetários, como: qualidade ambiental, tempo pessoal e saúde.

Marques (2005) apresenta várias técnicas utilizadas para avaliação econômica de transportes, como: a) *análise custo-benefício* - compara o incremento dos benefícios com o incremento dos custos; b) *análise do custo do ciclo de vida* - é a análise custo benefício que incorpora, no tempo, o valor do dinheiro, permitindo uma comparação entre alternativas que prevêm custos e benefícios em tempos diferentes; c) *análise custo-eficácia* - compara os custos de diferentes opções para alcançar um determinado objetivo, sendo que a quantidade de benefícios é mantida constante ao longo da análise e os custos de contribuição passam a ser a única variável; d) *análise da avaliação de*

contas múltiplas - incorpora critérios tanto qualitativos quanto quantitativos, podendo ser usado quando há uma dificuldade em quantificar financeiramente um impacto; e) *análise de menor custo para planejar* - é um tipo de análise custo-benefício que considera uma administração de demanda em condições iguais, com expansão de capacidade.

7.4. O SOFTWARE HDM-4

Não é objetivo dessa seção detalhar o *software* HDM-4, sendo indicados para esse fim, os manuais que acompanham o programa. Nesse trabalho, o propósito é apenas apresentar uma visão geral do *software* e suas potencialidades.

No Brasil, um dos *softwares* mais usados para gerência de pavimento é o HDM-4 (*Highway Development and Management*), desenvolvido pelo Banco Mundial, que tem sido utilizado para avaliar técnica e economicamente projetos de rodovias, preparar programas de investimentos rodoviários e analisar estratégias (NASCIMENTO, 2005).

As condições atuais dos pavimentos das rodovias são os dados de entrada para o HDM-4, tais como: extensão, estrutura, volume de tráfego, defeitos (condições superficiais), irregularidade (condições de rolamento), deflectometria (condições estruturais), geometria (largura de pista, largura de acostamentos, declividades médias, índice de curvatura, etc), condições climáticas, topografia, idade do pavimento, idade da última restauração, etc. (PIARC, 2006).

Outras informações também fazem parte dos dados de entrada, como: a) dados da frota nacional (tipo de veículos, peso, custos de aquisição e de manutenção, custo do combustível); b) as políticas de intervenção (tipo de manutenção ou restauração e custo); c) os cenários de investimento (PIARC, 2006).

De acordo com Carvalho *et al.* (1996), as principais aplicações do HDM-4 são: a) *no planejamento rodoviário* - objetivando a preservação da rede

rodoviária, é utilizado como suporte para a justificativa de solicitação e previsão de recursos financeiros; b) *nas aplicações técnicas* - auxilia na determinação de estratégias ótimas de manutenção e de limites econômicos para o melhoramento das rodovias, inclusive na escolha de opções de projeto e manutenção e, também, na simulação do tipo e dimensão da deterioração provável do pavimento; c) *na análise econômica* - facilita a análise da atribuição dos custos e das despesas relativas ao uso das rodovias, estabelecendo preços e taxações do transporte rodoviário.

7.4.1. BREVE HISTÓRICO

Em 1969, visando ao desenvolvimento de uma metodologia para análise econômica de projetos rodoviários para países em desenvolvimento, deu início aos estudos para a criação do HDM-III, considerada a versão comercial do *software*.

A estrutura conceitual e o primeiro modelo de custos rodoviários, relacionando os custos de construção, manutenção e operação de veículos, foram desenvolvidos até 1971.

Entre 1971 e 1975, desenvolveram-se estudos visando à obtenção de resultados experimentais que pudessem servir de base empírica para o desenvolvimento teórico do modelo.

O Brasil colaborou com o maior estudo de campo, entre 1975 e 1984, sendo conduzido por uma equipe de especialistas brasileiros (GEIPOT) e de outros nove países, financiado pelo Governo Brasileiro e pelo Programa de Desenvolvimento das Nações Unidas.

O desenvolvimento da etapa final do *software* foi possibilitado pela análise da base de dados das pesquisas de campo, principalmente os resultados obtidos no Brasil, referente aos modelos de previsão dos custos de operação dos veículos e da evolução da deterioração das rodovias. Em 1987, o Banco Mundial divulgou as publicações do HDM-III, referentes à documentação das pesquisas e, em 1989, apresentou a versão para microcomputadores.

O *International Study of Highway Development and Management* (ISOHDM), com interesse de estender o alcance do HDM-III e criar um sistema mais acessível para a gerência de pavimentos, com ferramentas adaptadas e computacionalmente mais amigáveis, desenvolveu o *Highway Development and Management Toll*, conhecido como HDM-4.

O HDM-4 difere da versão anterior, por considerar os efeitos de congestionamentos, analisar pavimentos asfálticos em climas frios, incluir diversos tipos e estruturas de pavimentos (inclusive os rígidos), além de considerar a segurança das rodovias e os efeitos ambientais, tais como: consumo de energia, poluição sonora e do ar (NASCIMENTO, 2005).

7.4.2. ALGUMAS CARACTERÍSTICAS DO HDM-4

A unidade básica de análise do HDM-4 é um segmento (subtrecho) homogêneo de rodovia, sendo possível aplicar várias opções de análise (condição da via, investimentos, custos, etc) para este segmento homogêneo.

O HDM-4 fornece a previsão de desempenho da rede viária e de avaliação de projetos, faz avaliações de alternativas de construção, manutenção e estratégias de intervenções, compara estimativa de custos, permite a análise de resultados, através da modificação de seus parâmetros mais importantes, tais como, composição de tráfego, custos, características da rede, taxa de retorno, etc.

Segundo Nascimento (2005), o HDM-4 é usualmente empregado em três níveis de decisões dentro do processo de gerência de pavimentos: a) *planejamento estratégico* - estimativa orçamentária a médio e longo prazo, necessário para o desenvolvimento e preservação da rede viária); b) *programação* - elaboração de programa de trabalho anual (ou plurianual) dentro da previsão orçamentária, selecionando as ações de manutenção, reabilitação ou reconstrução a serem executadas); c) *análise de projetos* (avaliação econômica ou de viabilidade técnica de diversos projetos rodoviários e seus efeitos no meio ambiente; incluem projetos típicos de manutenção e reabilitação de rodovias existentes, duplicações, reparos nos pavimentos e construção de novas rodovias).

O HDM-4 simula as alterações futuras na via com base nas informações

das condições atuais dessa via. A confiabilidade dos resultados depende essencialmente de dois fatores: a) *dos dados* - o quanto eles representam a realidade das condições atuais e os fatores que mais influenciaram nesses dados; b) *do modelo* - o quanto ele representa o comportamento real e como são feitas as interações entre os vários fatores considerados para a variedade de condições às quais o modelo é aplicado.

7.4.3. ARQUITETURA DO HDM-4

O HDM-4 é estruturado em módulos. Possui um módulo de gerenciadores de dados, um módulo de ferramentas de análise, um módulo de modelos e um módulo importação e exportação de dados, apresentados na Figura 7.3.




Figura 7.3 - Arquitetura do HDM-4
Fonte: adaptado de PIARC (2006)

7.4.3.1. MÓDULO GERENCIAMENTO DE DADOS (DATA MANAGERS)

Este módulo é dividido em quatro opções: a) Configurações do sistema (HDM Config); b) Intervenções na via (Road Works); c) Rede viária (Road Network); d) Frota de veículos (Vehicle Fleet) (PIARC, 2006).

(i) Configurações do sistema

O módulo *Configurações do sistema* é o local no qual se definem os parâmetros que serão utilizados e que devem refletir as condições locais da rede analisada.

(ii) Intervenções na via

O módulo *Intervenções na via* é o local no qual se definem, para as várias seções da rede analisada, características de melhorias e manutenção, inclusive com os custos unitários.

(iii) Rede viária

O módulo *Rede viária* é o local no qual se introduzem os dados que definem as características físicas das seções das vias da rede analisada.

(iv) Frota de veículos

O módulo *Frota de veículos* é o local no qual se definem os dados da frota de veículos que trafega na rede analisada.

7.4.3.2. MÓDULO FERRAMENTAS DE ANÁLISE (ANALYSIS TOOLS)

Este módulo é composto das seguintes ferramentas de análise: a) Análise de projetos (Project); b) Análise de programas (Program); c) Análise de estratégias (Strategy) (PIARC, 2006).

(i) Análise de projetos

Análise de projetos é a ferramenta utilizada na avaliação de um ou mais projetos ou opções de investimentos, definidos para um determinado período (anual, plurianual, etc), sendo útil para estimar a viabilidade técnica e econômica dos projetos de investimentos, através do desempenho estrutural e deterioração do pavimento, efeitos de intervenções nas vias sobre os custos,

custos e benefícios dos usuários, comparações econômicas entre alternativas de projetos. Os projetos típicos analisados incluem a manutenção e reabilitação das vias existentes, melhorias no pavimento, alargamento ou melhorias geométricas e construções de novos trechos.

(ii) Análise de programas

Análise de programas é a ferramenta usada para comparar os custos previstos sob o regime atual de gerência de pavimentos com os custos previstos por outro regime de gerência, através de diferentes alternativas de manutenção e melhorias, permitindo, assim, estimar os benefícios econômicos que poderiam ser gerados pela inclusão de outros projetos alternativos e que coubessem no orçamento disponível para a via. O HDM-4 disponibiliza, para segmentos discretos da rede viária, uma variada lista de alternativas de projetos. Na análise, o problema pode ser colocado como sendo o de procurar a combinação de alternativas de projetos em um número de seções na rede que otimize uma *função objetivo* sob restrição orçamentária.

(iii) Análise de estratégias

Análise de estratégias é a ferramenta utilizada para prever as necessidades, em médio e longo prazo, de toda uma rede gerenciada pelo órgão rodoviário, incluindo as vias principais, secundárias e locais. Aplica o conceito de *matriz de categoria da rede*, que envolve as categorias da rede definida de acordo com atributos que têm maior influência no desempenho dos pavimentos e nos custos dos usuários. Por exemplo, uma matriz de categoria da rede pode ser construída usando dois tipos de pavimento (asfáltico e concreto), quatro níveis de condições (muito bom, bom, regular e ruim) e três categorias de trânsito (alto, médio e baixo), resultando em 24 seções representativas do pavimento ($2 \times 4 \times 3$). Verifica-se, então, que a principal diferença entre a análise estratégica e a análise de programa é a forma como as seções são identificadas: a análise de programa lida com seções que são unidades físicas individuais e na análise de estratégia as seções são agrupadas, na matriz de categoria da rede, em todos os segmentos com

características semelhantes. Na análise, o problema pode ser colocado como sendo o de procurar a combinação de alternativas de projetos em um número de seções na rede que otimize uma *função objetivo* sob restrição orçamentária (semelhante à análise de programas).

7.4.3.3. MÓDULO DE MODELOS (MODEL)

O HDM-4 disponibiliza quatro modelos para as análises técnicas: a) Deterioração da via (RD); b) Efeitos das intervenções na via (WE); c) Efeitos sobre os usuários da via (RUE); d) Efeitos sociais e ambientais (SEE) (PIARC, 2006).

(i) Deterioração da via

A *Deterioração da via* é modelada para quatro classes de pavimentos: RA, concreto, pavimentada com blocos e não-pavimentado.

(ii) Efeitos das intervenções na via

Os *Efeitos das intervenções na via* são considerados em 4 classes de intervenções: a) manutenção de rotina - serviços realizados a cada ano ou em intervalos ao longo de um ano (ex: selagem de trincas, remendos, limpeza de drenagem lateral, etc); b) manutenção periódica - serviços realizados com intervalos de alguns anos (ex: recapeamento, reconstruções, etc); c) especial - serviços cuja frequência não pode ser estimada com certeza prévia (ex: remoção de terra em deslizamento, remoção de veículos em acidentes de trânsito, etc); d) serviços de melhoria - por exemplo, melhoria da geometria, alargamento da pista, etc, e; e) construção - novo trecho, viaduto, etc. As intervenções podem ser programadas para atender à evolução de um defeito específico (sendo a programação feita em intervalos fixos de tempo para serviços de manutenção), em datas fixas (para serviços de melhorias ou construção) ou em resposta a níveis limites especificados (por exemplo, um determinado tipo de intervenção deverá ser realizada quando a área de trincamento exceder a um limite pré fixado).

(iv) Efeitos sobre os usuários

Os *Efeitos sobre os usuários* compreendem as análises da velocidade de veículos motorizados (custos de operação e tempo de viagem), velocidade de veículos não-motorizados (custos de operação) e segurança da via (custos de acidentes). As principais classes de veículos motorizados são as motocicletas, automóveis, utilitários, caminhões e ônibus. As velocidades dos veículos e o consumo dos componentes nos custos de operação são calculados como funções das características de cada veículo, da geometria da via, do tipo de superfície da condição atual da via e da condição de fluxo da via (livre ou congestionado). Os custos operacionais são determinados pelo produto de vários insumos consumidos, por seus preços unitários. Os custos financeiros representam os custos reais de posse e utilização do veículo na via. Os custos econômicos são os custos financeiros com ajustes feitos para permitir distorções dos preços de mercado decorrentes de taxas, subsídios, etc. O tempo de viagem é avaliado em termos da hora do passageiro a trabalho ou a passeio e do tempo de espera de cargas. Os custos do tempo de viagem são expressos em termos econômicos. Quanto à acidentes, permite a descrição de taxas de acidentes esperadas, definidas de acordo com conjunto de atributos da via e do trânsito, podendo ser especificado taxas de acidentes de cada severidade (fatais, ferimentos ou danos) em termos de acidentes por milhão de veículos por quilômetro.

(v) Efeitos sociais e ambientais

Os *Efeitos sociais e ambientais* contemplam a análise do balanço de energia e a emissão de poluentes, sendo considerados nas políticas de investimentos e projetos, para a redução da poluição e do consumo de recursos energéticos, além da redução dos custos de operação dos veículos.

7.4.3.4. MÓDULO DE IMPORTAÇÃO E EXPORTAÇÃO DE DADOS

Os dados para análise do HDM-4 podem ser importados de banco de dados existentes, por exemplo, de SGPs, de sistemas de informações sobre rodovias, etc. Esses dados origens devem estar organizados de acordo com a

estrutura de leitura de dados do HDM-4, ou seja, seguindo os modelo do Módulo Gerenciamento de Dados - HDM Config, Road Works, Road Network e Vehicle Fleet (PIARC, 2006).

Os atributos físicos dos dados originais, se necessário, devem ser exportados para um formato de arquivo compatível com o HDM-4, permitindo que todos os dados requeridos pelo programa possam ser diretamente importados.

Regras de transformação de dados, também se necessário, devem ser implementadas para converter os dados de origem para a base de dados do HDM-4. Por exemplo, se no banco de dado origem os defeitos “panela” foram armazenadas em termos de percentual de área da superfície do pavimento, há necessidade de transformar esse dado em número de unidade de panela padrão exigida pelo HDM-4. Seguindo o mesmo raciocínio, outros dados requeridos pelo HDM-4, por exemplo, fatores de calibração de deterioração do pavimento, devem ser inseridos como valores padrões pré-definidos de acordo com o tipo de pavimento, classe da rodovia, etc.

Dados como características da frota de veículos, manutenção da via, melhorias de um modo geral, unidade monetária e parâmetros de análise econômica podem ser armazenados diretamente na base de dados do HDM-4.

7.5. INTEGRAÇÃO DOS DADOS

Órgãos e/ou empresas de gestão rodoviária precisam desenvolver seus programas rodoviários baseados nas análises do HDM-4 para obter recursos financeiros de bancos internacionais que fomentam atividades nessa área, a juros baixos e prazo de pagamento dilatado. O alto custo da aquisição de dados espaciais, aliado à complexidade das análises sobre os pavimentos rodoviários, parece ser um fator limitante na utilização do HDM-4, fazendo com que os recursos de investimento na gestão rodoviária venham de outras fontes, muitas vezes escassos, com juros altos e prazo de pagamento curto.

Para amenizar o problema, torna-se fundamental, entre várias ações,

desenvolver procedimentos de campo que minimizem os custos de aquisição dos dados. Diante desse panorama, esta tese vem contribuir com novas pesquisas tecnológicas para se fazer o levantamento de defeitos superficiais dos pavimentos asfálticos e a determinação das camadas do pavimento, minimizando e agilizando os custos dessa atividade, conforme relatado nos Capítulos 4, 5 e 6.

Essa seção tem por objetivo analisar como é feita a entrada desses dados no HDM-4 e como proceder para que os dados sejam lidos pelo sistema. A proposta inicial, de utilização dos dados gerados nos Capítulos 4, 5 e 6, não foi possível, devido os dados serem insuficientes (em termos quantitativos) para serem analisados pelo HDM-4.

7.5.1. DEFEITOS SUPERFICIAIS MODELADOS NO HDM-4

O HDM-4 analisa pavimentos asfálticos, de concreto, pavimentado com blocos e não-pavimentados. Os defeitos que são modelados no HDM-4, conforme o tipo de pavimento, estão mostrados na Tabela 7.3.

Tabela 7.3 - Defeitos de pavimentos modelados no HDM-4
Fonte: adaptado de PIARC (2006)

Asfáltico	Concreto	Bloco	Não-pavimentado
trincas	trincas	trilha de roda	perda de agregado
panela	quebra nas juntas	irregularidade	irregularidade
textura da superfície	desnível na junta	textura da superfície	
trinca na borda	defeitos gerais		
trilha de roda	irregularidade		
irregularidade			
desagregação			
resistência a derrapagem			

Dois aspectos são relevantes no que diz respeito aos dados no HDM-4: as unidades dos dados e a forma de entrada dos dados. As informações apresentadas nas subseções seguintes referem-se ao pavimento asfáltico, muito embora, no que diz respeito à entrada de dados, o procedimento seja o mesmo para qualquer tipo de pavimento. Ressalta-se que a unidade de análise do HDM-4 são as “seções”. Portanto, as unidades dos dados e a entrada

desses dados são em relação às “seções”.

7.5.1.1. UNIDADES DOS DADOS

Os defeitos e as unidades usadas pelo HDM-4, nem sempre coincidem com as usuais no Brasil. Os defeitos de superfície considerados são: a) todas as trincas estruturais; b) trinca estrutural larga; c) trinca térmica transversal; d) desagregação; e) panelas; f) quebra de borda.

(i) Todas as trincas estruturais (%)

As trincas consideradas são: couro de jacaré, irregular, em bloco, transversal e longitudinal.

De acordo com o grau de severidade as trincas são definidas: a) Classe 1 - trincas $\leq 1\text{mm}$ de largura; b) Classe 2 - trincas de 1 a 3 mm de largura; c) Classe 3 - trincas $> 3\text{mm}$ de largura e sem erosão nas bordas; d) Classe 4 - trincas com erosão nas bordas.

Para trincas lineares, sua área é definida por um retângulo de 0,5m de largura pelo comprimento da trinca. Para as outras trincas, sua área é definida por um retângulo que as contém. A trinca Classe 1 não é considerada no cálculo devido à dificuldade em caracterizá-la no campo.

A unidade de *todas as trincas estruturais* é porcentagem. Calcula-se a soma das áreas das trincas em relação à área de pista da seção analisada.

(ii) Trincas estruturais largas (%)

É a trinca Classe 4. Para trincas lineares, sua área é definida por um retângulo de 0,5m de largura pelo comprimento da trinca. A unidade das *trincas estruturais largas* é porcentagem. Calcula-se a soma das áreas das trincas em relação à área de pista da seção analisada.

(iii) Trincas térmicas transversais (%)

Sendo uma trinca linear, sua área é definida por um retângulo de 0,5m de largura pelo comprimento da trinca. A unidade das *trincas térmicas transversais* é porcentagem. Calcula-se a soma das áreas das trincas em relação à área de pista da seção analisada.

(iv) Desagregação (%)

A unidade da *desagregação* é porcentagem. Calcula-se a soma das áreas das desagregações em relação à área de pista da seção analisada.

(v) Panelas (nº/km)

É medida em termos de “unidades de panela”, que é uma área de cerca de 0,1 m² por 100 mm de profundidade, corresponde a um volume de 10 litros. Em termos práticos, cada 0,1 m² de panela corresponde a uma unidade de panela. Mede-se a área das panelas (em m²), divide-se por 0,1 m² e divide o resultado pelo comprimento da seção em km (nº/km).

(vi) Quebra de borda (m²/km)

Medir a largura e multiplicar pelo comprimento, em m². Somar todas as ocorrências e dividir pelo comprimento da seção em km (m²/km).

Outros defeitos analisados pelo HDM-4, porém não abordados nesta tese são: irregularidade, trilha de roda (valor médio), trilha de roda (desvio padrão), profundidade da textura e resistência à derrapagem.

7.5.1.2. ENTRADA DE DADOS

Independentemente do tipo de pavimento, a entrada de dados no HDM-4 pode ser feita de duas maneiras: usando a *interface* do programa ou introduzindo os dados diretamente no seu banco de dados.

(i) Usando a interface

Inicialmente, no *Workspace*, clicar na pasta *Road Networks* e escolher a rede na qual se vai colocar os dados sobre defeitos superficiais, dando um duplo clique sobre ela - Figura 7.4.




Figura 7.4 - Escolha da rede no workspace

A janela aberta após o duplo clique dá informações sobre a rede escolhida, mostrando as seções que fazem parte dessa rede - Figura 7.5.

ID	Description	Data Last Modified	Surface Class	Pavement Type
BR267	Juiz de Fora Caxambu	12/09/2009	Bituminous	Asphalt Mix on Granular Base
Sec A	Seção A	12/09/2009	Bituminous	Asphalt Mix on Granular Base
Sec B	Seção B	12/09/2009	Bituminous	Asphalt Mix on Granular Base
Sec C	Seção C	12/09/2009	Bituminous	Asphalt Mix on Granular Base
Sec D	Seção D	12/09/2009	Bituminous	Asphalt Mix on Granular Base

Figura 7.5 - Janela mostrando as seções da rede escolhida

Agora, dá-se um duplo clique sobre a seção que se quer introduzir os dados. Na janela que abre, clicar sobre a guia *Condition* - Figura 7.6. As opções para a entradas dos dados estão disponíveis bastando clicar no campo em frente ao defeito e digitar o valor. Após, clicar no botão “ok”.

Section: Seção A

Definition | Geometry | Pavement | Condition | Other

Condition at end of year	2005
Roughness (IRI - m/km)	2.00
All Structural Cracks (%)	0.00
Wide Structural Cracks (%)	0.00
Thermal Cracks (%)	0.00
Ravelled area (%)	1.00
Number of Potholes (No./km)	0.00
Edge break area (m²/km)	0.00
Mean rut depth (mm)	2.00
Rut depth standard deviation (mm)	0.64
Texture depth (mm)	0.70
Skid resistance (SCRIM 50km/h)	0.50
Drainage	Good

Figura 7.6 - Janela para introduzir os dados sobre os defeitos

Para os dados das outras seções da via repetir o mesmo procedimento.

(ii) Introduzindo os dados diretamente no banco de dados

O HDM-4 tem o seu banco de dados na extensão *mdb*, que é a extensão proprietária do *software* Access, da *Microsoft*. A tarefa de introduzir os dados gerados é relativamente simples, bastando achar entre as várias tabelas utilizadas pelo HDM-4 qual é aquela que traz os dados referentes à deterioração do pavimento.

A seguir mostra-se como acessar a tabela que contém os dados dos defeitos de superfície.

Inicialmente achar o arquivo “RunData.mdb” do projeto que se está analisando, utilizando o gerenciador de arquivo do sistema operacional - Figura 7.7.




Figura 7.7 - Localização do arquivo Access do projeto

Após, abri-lo no *software* Access - Figura 7.8.




Figura 7.8 - Opções das tabelas do arquivo *Rundata.mdb*

Dentre as tabelas que compõem esse arquivo, dar um duplo clique na tabela *Sections* para ter acesso aos dados da tabela. Agora, basta identificar as colunas dos defeitos, introduzir os dados para cada seção da via e salvar a tabela. As colunas são: CRACKS_ACA (todas as trincas estruturais), CRACKS_ACW (trincas estruturais largas), CRACKS_ACT (trincas térmicas), RAVEL_AREA (desagregação), PHOLE_NUM (painéis) e EDGEBREAK (quebra de borda).

No que diz respeito às camadas do pavimento, sua informação é necessária para o cálculo do número estrutural do pavimento (SN) e não depende de explicações devido à simplicidade de entrada desse dado no HDM-4.

7.5.2. DADOS OBTIDOS COM AS IMAGENS DIGITAIS E USADOS NO HDM-4

Nos Capítulos 4, 5 e 6 abordaram-se formas de se classificar imagens digitais, cujos resultados teriam, como aplicação prática, sua inserção no *software* HDM-4. No entanto, essa possibilidade só ocorreria se os dados fossem obtidos ao longo de um segmento homogêneo de rodovia, que é a unidade mínima de avaliação do HDM-4. Como não foi possível nesse trabalho obter-se imagens ao longo de um segmento homogêneo, esse procedimento não foi implementado. Para finalizar, ressalta-se que a qualidade das informações extraídas nas imagens digitais atende ao HDM-4, o que faltou, foi

quantidade de informações.

7.6. RESUMO DO CAPÍTULO

Como resumo desse capítulo, destaca-se o procedimento de entrada dos dados sobre defeitos superficiais do pavimento no *software* de Sistema de Gerência de Pavimento HDM-4, concluindo que há duas possibilidades de fazê-lo e, em ambas, os procedimentos são relativamente simples.

Como aplicação prática, identificados e extraídos os defeitos superficiais dos pavimentos, calculados e convertidos convenientemente nas unidades do HDM-4, basta usá-los normalmente como dados de entrada no projeto que está sendo analisado, como descrito na subseção 7.5.1.2.

CAPITULO 8

CONCLUSÕES E RECOMENDAÇÕES

8.1. RESUMO E CONCLUSÕES

A automatização das técnicas de avaliação de pavimentos vem se tornando uma tendência mundial e, nesta tese, propôs-se utilizar imagens digitais do pavimento rodoviário, tanto em nível orbital como em nível terrestre, para extrair informações com o objetivo de auxiliar na avaliação de pavimentos rodoviários, em substituição aos métodos manuais e de interpretação visual usados no Brasil. As características analisadas do pavimento foram os defeitos superficiais trinca, panela e remendo e as camadas do pavimento. Utilizaram-se, sobre as imagens do pavimento, técnicas de reconhecimento automático de padrões, com classificação supervisionada e regra de decisão com os algoritmos de Máxima Verossimilhança e Redes Neurais Artificiais e, em alguns casos, Morfologia Matemática.

Para a análise dos defeitos de superfície utilizou-se uma imagem orbital e uma imagem terrestre, ambas multiespectrais e cujas faixas espectrais utilizadas foram definidas em função da conclusão do Capítulo 3 sobre discriminação espectral dos padrões de RA. A imagem orbital usada foi a do sensor *QuickBird 2*, considerado de altíssima resolução espacial. Já a imagem terrestre foi construída (imagem sintética) com características para atender às curvas espectrais dos padrões de RA. Em ambas as imagens os dados espectrais foram as variáveis discriminatórias no procedimento de reconhecimento automático de padrões.

Para a análise dos defeitos de superfície utilizando imagens monocromáticas, usou-se a textura como variável discriminatória no procedimento de reconhecimento de padrão. A extração da textura das imagens foi através da Transformada *Wavelet* e Morfologia Matemática. Criaram-se metodologias para cada um dos procedimentos.

Quanto à análise das camadas do pavimento, utilizaram-se duas imagens da subsuperfície, obtidas com o GPR. Em ambas usou-se a mesma metodologia das imagens terrestres monocromáticas para caracterizar defeitos de superfície do pavimento (classificação supervisionada com extração da textura pela Transformada *Wavelet*). A Morfologia Matemática não foi apresentada neste caso, pois testes preliminares apresentaram resultados ruins.

Como uma aplicação prática do uso das imagens classificadas, verificou-se a possibilidade de utilizá-las em um sistema de gerência de pavimento e elegeu-se o *software* HDM-4 para fazer essa verificação. O HDM-4 é o *software* de gerência de pavimentos mais utilizado no Brasil para avaliar técnica e economicamente projetos de rodovias, preparar programas de investimentos rodoviários e analisar estratégias.

Com relação aos resultados obtidos nos vários experimentos, descrevem-se as principais conclusões:

Através da análise das curvas espectrais de padrões de defeitos do pavimento asfáltico, obtidos com um espectrorradiômetro que opera na faixa de 350 nm a 2.500 nm, concluiu-se que os dados espectrais podem ser usados para discriminar os diferentes padrões da superfície dos pavimentos asfálticos e que um sensor que opera na faixa de 400 a 755 nm atenderia satisfatoriamente para discriminar os padrões analisados, que foram: a) RA novo e em bom estado; b) RA velho e em bom estado; c) trinca com baixo grau de deterioração; d) trinca com alto grau de deterioração. Através dessa análise definiu-se que um sensor que abrangesse a faixa da luz visível e o infravermelho próximo atenderia perfeitamente para a análise dos defeitos de superfície do pavimento asfáltico através dos dados espectrais da imagem.

A principal conclusão do experimento com imagem orbital, através dos dados espectrais da imagem, é que a resolução espacial dessas imagens, embora considerada como de altíssima resolução, ainda não é suficiente para detectar defeitos superficiais em pavimentos asfálticos. As classes analisadas

não foram bem discriminadas, havendo uma razoável confusão entre elas. A expectativa é que muito em breve, com a evolução na melhoria da resolução espacial das imagens orbitais, essa possibilidade seja aplicável.

Quanto ao uso de imagens terrestres, os resultados da análise de dados espectrais confirmam que esse caminho é bastante promissor. As regras de decisão utilizadas - algoritmo MaxVer e RNA apresentaram excelentes resultados e, tanto um quanto o outro, podem ser indicados para a tarefa de reconhecimento automático de padrões em defeitos superficiais de pavimentos. O único problema a levantar é que essa análise foi feita sobre uma imagem sintética e não imagem real.

Quanto às imagens terrestres monocromáticas, analisaram-se seis imagens e usou-se a textura como variável discriminatória. A extração da textura pela Transformada *Wavelet* aponta como opção promissora, confirmada pelos resultados das regras de decisão utilizadas na classificação supervisionada das imagens - MaxVer e RNA. Em relação ao par de extratores, utilizados sobre os coeficientes *Wavelets* das imagens e o valor numérico dos *pixels* (ICW e média dos brilhos), mostraram-se bem representativos das características das imagens analisadas.

Quanto à análise da textura utilizando morfologia matemática, concluiu-se que para analisar trincas (feições lineares) e buracos sobre as imagens, os resultados são considerados bons, não havendo qualquer dificuldade para uma interpretação visual. Já o defeito “remendo” não foi bem discriminado na imagem e a morfologia matemática não apresentou nenhuma melhora na imagem para sua interpretação visual.

No que diz respeito aos resultados das duas imagens do GPR, concluiu-se que considerando a qualidade do radargrama - obtido com um GPR de 900 MHz, bem inferiores aos usuais para pavimento rodoviário, que é acima de 1,6 GHz, os resultados da classificação supervisionada utilizando as regras de decisão MaxVer e RNA apontam como uma opção promissora. Acredita-se que com a melhoria da resolução do radargrama os resultados seriam bem

melhores. O mais animador é que os testes comprovaram que é possível fazer a análise automática do radargrama, abrindo uma grande possibilidade nessa área, visto que, até mesmo em nível mundial, não há praticamente esforço algum nessa abordagem, fazendo-se apenas a interpretação visual dos radargramas.

Finalmente, quanto à utilização dos resultados obtidos na análise das imagens, ou seja, defeitos na superfície do pavimento asfáltico e determinação das camadas do pavimento, no *software* de gerência HDM-4, a conclusão é que não há qualquer dificuldade, desde que os dados sejam preparados de acordo com a formatação do HDM-4 e que se tenha os dados ao longo de um segmento homogêneo.

Diante das conclusões dessa seção, baseada em todos os experimentos desenvolvidos nesta tese, a hipótese 1 foi parcialmente aceita, visto que a análise de defeitos superficiais com imagem orbital não deu resultados aceitáveis. A hipótese 2 foi plenamente aceita. A hipótese 3 também foi parcialmente aceita, pois muito embora seja possível usar dados extraídos de imagens digitais do pavimento no *software* HDM-4, os dados obtidos nessa tese não foram suficientes, em termos quantitativos, para serem utilizados no HDM-4.

8.2. RECOMENDAÇÕES PARA PESQUISAS FUTURAS

Considerando: a) a importância de procedimentos que venham contribuir para a avaliação dos pavimentos rodoviários brasileiros; b) que estes procedimentos automatizados podem vir a substituir as técnicas em uso no Brasil; c) que a obtenção de dados sobre o pavimento rodoviário é uma atividade onerosa e que, por esse motivo, são determinados, quase sempre, estatisticamente; d) que novas tecnologias que minimizem o custo desses dados e, simultaneamente, sejam mais representativas das condições do pavimento, serão muito bem aceitas pelos órgãos de gestão rodoviária; e) os resultados promissores obtidos nesta tese, sobre características dos pavimentos rodoviários com o uso de imagens digitais; f) que a pesquisa feita

nesta tese ainda é um passo relativamente pequeno em termos de resultados, mas grande em termos de conclusões; g) que a inovação tecnológica é a forma mais atraente para se obter riquezas para uma nação. Recomendam-se as seguintes ações para pesquisas futuras afetas ao tema abordado:

(i) Quanto à aquisição da imagem

As imagens superficiais do pavimento podem ser de origem orbital, sub-orbital e terrestre.

As imagens orbitais são adquiridas no mercado, através de empresas que comercializam essas imagens. A recomendação para essas imagens é que tenham a maior resolução espacial disponível entre todos os programas espaciais e que não haja nuvens e nem sombra de nuvens sobre as rodovias e que, também, haja o mínimo de trânsito possível, pois os veículos “cobrem” a rodovia, impedindo que se analisem os defeitos.

Quanto às imagens sub-orbitais, estas são adquiridas de empresas prestadoras de serviços. A recomendação para essas imagens é que devam ser digitais e com a maior escala possível (vão baixo). Há de se destacar duas novas tecnologias disponíveis no mercado: a tecnologia *laserscanner* e a tecnologia de imagem hiperespectral.

No que diz respeito às imagens terrestres, cujo sensor é possível ser adquirido no mercado, recomendam-se as seguintes características para o sistema sensor (câmera, suporte e dispositivo de posicionamento):

- câmera digital multiespectral com as seguintes características mínimas:
 - a) adquirir simultaneamente imagens nas quatro bandas espectrais que discriminam bem os defeitos do pavimento asfáltico (banda do visível e um trecho do infravermelho próximo - 400 a 1.050 nm);
 - b) ter uma resolução espacial que permita identificar uma trinca FC-2 e FC-3 - acima de 1 mm (DNIT 005/2003-TER);
 - c) ter uma lente que seja capaz de cobrir a largura de uma faixa de trânsito (3,50 m) estando até a 2,00 m do alvo e que não produza distorções

significativas nos bordos da imagem; d) ser capaz de adquirir imagens do pavimento com o veículo deslocamento a alta velocidade (até 100 km/h), sem arraste da imagem, tendo dispositivo de sincronização com a velocidade do veículo; e) ter capacidade de transferir os dados em alta velocidade para um computador instalado no interior do veículo; f) ser robusta o suficiente para atender as condições de campo; g) ter fonte de alimentação 12V, para ser ligada à bateria do veículo.

- desenvolver uma plataforma para a câmera terrestre, fixada a um veículo, com dispositivo para manter o eixo da câmera sempre ortogonal ao pavimento;

- desenvolver um dispositivo de posicionamento das imagens, que pode ser através de sensores fixados na roda do veículo ou na transmissão do veículo, ou um GPS. Esse dispositivo deve ser capaz de marcar intervalos de um em um metro.

Enfocando, agora, a aquisição de imagens da subsuperfície do pavimento com o uso do GPR, sugere-se o uso de um GPR de pelo menos 1,6 GHz, obtendo-se radargramas de melhores qualidades, possibilitando análises mais apuradas sobre eles. A análise automática dos padrões sobre o radargrama mostrou ser um caminho promissor, mas a sua qualidade influencia diretamente sobre essa análise. É imprescindível que todo e qualquer experimento seja validado com verificações locais. Dados como espessura de camada, umidade, densidade, etc, devem ser confirmados diretamente no campo. A criação de uma área teste, de fácil acesso aos dados de campo, com controle dos parâmetros analisados, contribuiria bastante para esse campo de aplicação do GPR. Essa área teste possibilitaria a análise de várias composições de pavimentos e sua correspondência com os radargramas, além da determinação de propriedades dielétricas dessas camadas, montando um banco de dados com essas informações.

(ii) Quanto ao processamento das imagens

Quanto às imagens orbitais, considerando o contexto da conservação rodoviária e devido à importância do sensoriamento remoto, recomenda-se o desenvolvimento de pesquisas abordando os dados multiespectrais de sensores de altíssima resolução, para atestar seu potencial e aperfeiçoar o seu uso na área rodoviária.

No que diz respeito às imagens sub-orbitais, a combinação da tecnologia *laserscanner* com imagens digitais parece ser uma área bem promissora. A tecnologia *laserscanner* permite a determinação de coordenadas tridimensionais de pontos do terreno com uma boa precisão. Os dados obtidos pela tecnologia *laserscanner* não possuem informações espectrais, mas podem ser analisadas usando os sistemas de processamento de imagens tradicionalmente desenvolvidos para as imagens de sensoriamento remoto, pois os dados dos levantamentos são grades *raster*. Assim, quanto ao uso dessa tecnologia no contexto rodoviário, recomenda-se:

- desenvolver um sistema sensor com a tecnologia *laserscanner*, semelhante ao sistema sensor com o uso de câmera digital (sistema sensor terrestre);

- pesquisar e testar todas as etapas de um sistema automático de reconhecimento de padrões, desenvolvidas especificamente para as imagens *laserscanner*, que devem atender tanto aos dados sub-orbitais quanto terrestres. Definições quanto às variáveis discriminatórias, extração das variáveis discriminatórias, extratores, regras de decisão, etc, devem ser pesquisadas.

Ainda, tratando de dados sub-orbitais, atenta-se para as imagens de sensores hiperespectrais, particularmente o sensor AVIRIS. Recomendam-se pesquisas no sentido de desenvolver técnicas que combine a espectrometria de campo com o sensoriamento remoto hiperespectral, objetivando o mapeamento das condições superficiais dos pavimentos.

Quanto às imagens terrestres (multiespectrais e monocromáticas),

recomenda-se:

- testar imagens terrestres multiespectrais reais para ver se os resultados são tão expressivos quanto foram com a imagem sintética multiespectral;
- no que diz respeito à Transformada *Wavelet*, testar outros níveis de resolução e outras famílias, comparando os resultados e o esforço computacional para executá-los;
- testar novos parâmetros ou conjunto de parâmetros como extratores, para a obtenção dos vetores de características, como por exemplo, *Wavelet* com PCA (análise de componentes principais);
- testar outras técnicas de classificação, como as baseadas em recuperação de imagens por conteúdo, classificação não-supervisionada, etc;
- desenvolver metodologias e procedimentos para a classificação de defeitos não abordados nesta tese: corrugação, trilha de roda, depressões e escorregamento de massa. Esses defeitos têm uma análise mais complexa, pois dependem da avaliação de sua altura.

Quanto às imagens obtidas pelo GPR, recomenda-se:

- no que diz respeito à Transformada *Wavelet*, testar outros níveis de resolução e outras famílias, comparando os resultados e o esforço computacional para executá-los;
- testar novos extratores sobre a imagem transformada e segmentada em blocos, uma vez que esse procedimento mostrou-se promissor;
- desenvolver um modelo para transformar, de uma forma automática, o tempo de penetração da onda em profundidade (distância), baseado na medida das feições hipérboles dos radargramas.

(iii) Quanto à norma para obtenção dos dados

A norma brasileira que faz referência à obtenção dos dados sobre defeitos superficiais de pavimento foi estabelecida para trechos homogêneos e segmentos testemunhas, que são representativos das condições do pavimento. O procedimento de se levantar defeitos com o uso de imagens é contínuo e cobre 100% das faixas de trânsito, inclusive o acostamento. Diante desse contexto, recomenda-se a elaboração de uma minuta de proposta para normalização do uso de imagens digitais na avaliação de defeitos de pavimentos e encaminhada aos órgãos competentes, tais como, o DNIT, ABNT, etc.

Quanto ao uso do GPR para extrair informações do pavimento, não existe norma brasileira sobre o assunto. Da mesma forma que no caso das imagens digitais para avaliar defeitos de pavimentos, recomenda-se a elaboração de uma minuta de proposta para normalização do uso do GPR no contexto da engenharia rodoviária que seja encaminhada aos órgãos competentes, tais como, o DNIT, ABNT, etc.

BIBLIOGRAFIA CITADA

AASHTO. Guide for Design of Pavement Structures. American Association of State Highway and Transportation Officials. Appendix K: Typical Pavement Distress Type-Severity Descriptions. Washington, D.C., 1986.

ABCR. Associação Brasileira de Concessionárias de Rodovias. Disponível em <http://www.abcr.org.br/conc/index.php>. Acesso em: 9 abr. 2008.

AGUIAR, J. C. M. Radar de penetração no solo (GPR): aspectos geofísicos e geodésicos, processamento e análise em pavimento flexível. 128 p. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação). Centro de Tecnologia e Geociência, Universidade Federal de Pernambuco. Recife. 2005.

AMER-YAHIA, C.; MAJIDZADEH, T. Use of ground penetrating radar for quality control measurement on new asphalt overlays. 11th International Conference on Ground Penetrating Radar. Columbus, Ohio. June. 2006.

ANNAN, A.P. Ground Penetrating Radar. Workshop Notes Sensors and Softwares, Inc. Canadá. 1992.

ANTT. Agência Nacional de Transportes Terrestres. Disponível em <http://www.antt.gov.br/concessaorod/apresentacaorod.asp>. Acesso em: 3 abr. 2008.

APS, M.; BALBO, J. T.; SEVERI, A. A. Avaliação superficial de pavimentos asfálticos em vias urbanas utilizando o método do PCI. In: Reunião Anual de Pavimentação, 31., 1998, São Paulo.

ARB. Catálogo dos Defeitos dos Revestimentos dos Pavimentos. Associação Rodoviária Brasileira. Trad. por Hugo Alves Pequeno. São Paulo, 1978.

ARRB Group Ltd. Disponível em www.arrb.com.au/index.php?option=com_content&task=view&id=64&Itemid=52. Acesso em: 8 abr. 2008.

AZEVEDO, A. M. Considerações sobre a drenagem subsuperficial na vida dos pavimentos rodoviários. Dissertação (mestrado em engenharia de transportes). Universidade de São Paulo. São Paulo. 2007. 156 p.

BARELLA, R.M. Inventário de defeitos superficiais de pavimentos com o auxílio de imagens digitais. 215 p. Dissertação (Mestrado em Engenharia de Transportes). Escola Politécnica, Universidade de São Paulo. São Paulo. 2001.

BENSON, R.C.; NOEL, M. Geophysical techniques for sensing buried wastes and waste migration. In: U.S. EPA Environmental Monitoring Systems Laboratory. Las Vegas. 1984. 236 p.

BISCHOF, H.; Schneider, W.; Pinz, A.J. Multispectral classification of Landsat images using neural networks. IEEE Transactions on Geoscience and Remote Sensing, v.30, n.3, p.482-490, May 1992.

BISHOP. C.M. Neural networks for pattern recognition. 1ed., Oxford. New York: Oxford University Press, 1995, 482p.

BORGES, W. R.; PORSANI, J. L. 2003. Caracterização geofísica rasa do sítio controlado do IAG-USP: resultados preliminares. VII Congresso Internacional da Sociedade Geofísica Brasileira. Rio de Janeiro. CDrom.

_____. 2005. Utilização de metodologias geofísicas na identificação de manilhas de concreto.... IX Congresso Internacional da Sociedade Geofísica Brasileira. Salvador. CDrom.

CAMPOS, A.C.R. Métodos de previsão de desempenho de irregularidade longitudinal para pavimentos asfálticos: aplicação e proposição de critérios de ajuste. Dissertação (mestrado em engenharia civil). Faculdade de engenharia, arquitetura e urbanismo. Universidade Estadual de Campinas. 2004.

CARVALHO, M.D.; HALLACK, A.; SILVA, E.L.S. O projeto HDM-4. Federação Interamericana de Cimento (FICEM). 30ª Reunião Anual de Pavimentação, Salvador. Bahia: Associação Brasileira de Pavimentação, v. IV, 1996.

CASTAÑÓN, C. A. B. Recuperação de imagens por conteúdo através da análise multirresolução por wavelets. 112 p. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo, São Carlos. 2003.

CASTELO, H.; GOULIAS, D. G.; BENSON, K.; HUDSON, W. R. Distress Identification Manual for the Long-Term Pavement Performance Studies. SHRP-87-P001, 1990.

CASTLEMAN, K.R. Digital Image Processing. Cidade: New Jersey: Prentice Hall, 1996.

CNT - Confederação Nacional do Transporte. Pesquisa Rodoviária 2007 - Relatório Gerencial. Brasília. CNT, 2007.

CONGALTON, R. G.; GRENN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. New York: Lewis Publishers, 1999.

CONGALTON, R. G.; MEAD, R.A. A review of assessing the accuracy of classifications of remote sensed data. Remote Sensing of Environment, v.37, n.1, p. 35-46, 1991.

CONCER. Disponível em <http://www.concer.com.br/>. Acesso em: 3 abr. 2008.

CRÓSTA, A.P. Processamento digital de imagens de sensoriamento remoto. ed. rev. Campinas: IG/UNICAMP, 1993. 170 p.

CUHADAR, A.; SHALABY, A.; TASDOKEN, S. Automatic segmentation of pavement condition data using Wavelet transform. Proceeding of the IEEE Canadian Conference on Electrical and Computer Engineering. IEEE. 2002.

DAVIS, J.L.; ANNAN, A.P. Ground Penetrating Radar for High-Resolution Mapping of Soil and Rock Stratigraphy. Geophysical Prospecting, 37: 531-551. 1989,

DOMINGUES, F.A.A. MID - Manual para Identificação de Defeitos de Revestimentos Asfálticos de Pavimentos. São Paulo: LDTT/PTR/ EPUSP, 1993.

DOMINGUES, F.A.A.; CAMPOS, O.S.; REBAÇA, S.R. Indicadores para avaliação da condição dos pavimentos da rede DERSA. 30ª Reunião Anual de Pavimentação, Salvador. Bahia: Associação Brasileira de Pavimentação, v. IV, 1996.

DOURADO, T.C. Aplicação de técnicas do processamento sísmico de reflexão em dados de radar (GPR) para detecção de hidrocarbonetos em sedimentos arenosos. Dissertação (Mestrado em Geofísica). Instituto de Geociências, Universidade Federal da Bahia. Bahia. 2004.

DNER-PRO 011/79 – Departamento Nacional de Estradas de Rodagem. Avaliação Estrutural dos Pavimentos Flexíveis. Rio de Janeiro: DNER, 1979.

DNER-PRO 159/85 - Departamento Nacional de Estradas de Rodagem. Projeto de restauração de pavimentos flexíveis e semi-rígidos. Rio de Janeiro: DNER, 1985.

DNIT - Departamento Nacional de Infra-estrutura de Transportes. Manual de restauração de pavimentos asfálticos. Diretoria de Planejamento e Pesquisa/IPR, R.J. 2 ed. 310 p. 2005.

_____. Terminologia rodoviária usualmente utilizadas. Diretoria de Planejamento e Pesquisa. Brasília, ago. 2007. 14 p. CDrom.

_____. Resumos Gerais da Divisão em Trechos do PNV versão 2006 - Arquivos do Excel. Disponível em: [http://www.dnit.gov.br/menu/rodovias/rodoviasfederais/arquivos/PNV2006Resumo Gerais2006.xls](http://www.dnit.gov.br/menu/rodovias/rodoviasfederais/arquivos/PNV2006Resumo%20Gerais2006.xls). Acesso em: 5 mar, 2008a.

_____. Disponível em: <http://www.dnit.gov.br/menu/rodovias/planejamentos/gerencia>. Acesso em: 24 mar. 2008b.

_____. Disponível em: http://www.dnit.gov.br/menu/pac/pac_inicio. Acesso em: 24 mar. 2008c.

_____. Disponível em [www.dnit.gov.br /menu/dpp](http://www.dnit.gov.br/menu/dpp). Acesso em: 3 abr. 2008d.

ESTRADAS. Disponível em: [http://www.estradas.com.br/materia_brasil% 20gig_rodov.htm](http://www.estradas.com.br/materia_brasil%20gig_rodov.htm). Acesso em: 25 mar. 2008.

FERNANDES JR., José L.; ODA, S.; ZERBINI, L. F. Defeitos e atividades de manutenção e reabilitação em pavimentos asfálticos - São Carlos, EESC, 1999.

FERREIRA, A.B.H. DICIONÁRIO mini dicionário aurélio da língua portuguesa. Curitiba: editora positivo, 2009.

FONSECA, L.M.G. Capítulo 7: Segmentação e classificação. 2000. [on line].Disponível em www.dpi.inpe.br/~leila/ser437/PDI_7_seg_clas.pdf. Acesso em: 5 mar. 2006.

FRACASSO, P. Sistemas de dunas do parque das dunas e Barreiras do Inferno/Natal (RN): levantamento geológico /geofísico, elaboração do modelo determinístico e avaliação da vulnerabilidade/suscetibilidade. 184 p. Dissertação (Mestrado em Geodinâmica). Centro de Ciências Exatas e da Terra, Universidade Federal do Rio Grande do Norte. Natal. 2005.

FUGRO Roadware. Disponível em www.roadware.com/products_services/aran/. Acesso em: 2 de jun. 2008.

GLERIANI, J.M. Redes neurais artificiais para classificação espectro-temporal de culturas agrícolas. 212p.Tese. Instituto Nacional de Pesquisas Espaciais. São José dos Campos. 2004.

GONÇALVES, F.P.; CERATTI,J.A.P. Utilização do ground penetration radar na avaliação de pavimentos. 31ª Reunião Anual de Pavimentação. São Paulo. Anais. v. 1. p. 390-403. 1998.

GONZALEZ R.C.; WOODS R.E. Digital image processing. 2. ed. New Jersey: Prentice Hall, 2002. 822 p.

HARA *et al.* 1994., Application of neural networks to radar image classification. IEEE Transactions on Geoscience and Remote Sensing, 32, p. 100-109.

HARALICK, R.M.; SHUNMUGAN, K.; DISTEIN, I. Texture feature for image classification. IEEE Transactions Systems, Man and Cybernetics. v. 3, n. 6, p. 6610-21, 1973.

HASS, R. *et al.* Modern pavement management. Florida: Krieger Publishing, 1994.

HAYKIN, S. Redes neurais: princípios e práticas. 2ed. Traduzido: Paulo Martins Engel. Editora Bookman. Porto Alegre, 2001. 900p.

HE, H.; COLLET, C. Combining spectral and textural features for multispectral image classifications with artificial neural network. In: International archives of photogrammetry and remote sensing. Proceedings. Valladolid: Espanha, Jun. 1999. v.32, p.175-181.

- HEINEN, M.R. Autenticação on-line de assinaturas utilizando redes neurais. Monografia. Informática. Universidade do Vale do Rio dos Sinos. São Leopoldo, RS. 2002. 92 p.
- HEROLD, M; GARDNER, M.E.; NORONHA, V.;ROBERTS, D.A. Spectrometry and hyperspectral remote sensing of urban road infrastructure. 2003. [on line]. Disponível em www.satjournal.tcom.ohiou.edu/pdf/herold.pdf. Acesso em: 12 ago. 2007.
- HEROLD, M; ROBERTS, D.A.; GARDNER, M.E.; DENNISON, P.E. Spectrometry for urban area remote sensing - development and analysis of a spectral library from 350 to 2400 nm. In: Remote Sensing of Environment, 91., 2004, p. 304-319.
- HEROLD, M; ROBERTS, D.A; SMADI, O.; NORONHA, V. Road condition mapping with hyperspectral remote sensing. 2004a. [on line]. Disponível em [ftp://jpl.nasa.gov/pub/docs/workshops/04_docs/Herald_et_al_aviris_2004_web.pdf](http://jpl.nasa.gov/pub/docs/workshops/04_docs/Herald_et_al_aviris_2004_web.pdf). Acesso em: 02 ago. 2007.
- IMAGESURVEY. Disponível em <http://www.imagesurvey.com.br/2008/09/matriz-de-co-ocorrencia-o-que-e-e-como-se-faz/>. Acesso em: 19 abr. 2009.
- JENSEN, B. C. Manual of Remote Sensing. Urban/Suburban land use analysis. Falls Church, American Society of Photogrametry, 1983, 2 ed, v2, cap. 30, p. 1571-1666.
- KLEIN, F. C. Análise da influência de características geométricas de rodovias nos custos dos usuários utilizando o programa HDM-4. Dissertação (Mestrado em engenharia de transportes). Universidade de São Paulo. São Paulo, 2005.
- LANDGREBE, D. A. Signal Theory Methods in Multispectral Remote Sensing. New Jersey: John Wiley and Sons, 2003. 508 p.
- LATORRE, M. L. Utilização de um método de correção atmosférica para o processamento de dados hiperespectrais do sensor AVIRIS em regiões tropicais. 202 p. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisa Espacial. São José dos Campos, 1998.
- LEONARDI, F.; SILVA, R.A. Aplicação de morfologia matemática para extração em drenagens. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO, 8., 2008, Florianópolis.
- LERCH, R.L. Previsão de irregularidade pós-recapê em rodovias do RS: ajuste do modelo HDM-4. Dissertação (mestrado em engenharia civil). Engenharia Civil. Universidade Federal do Rio Grande do Sul. Porto Alegre. 2002. 130 p.
- LIANG, S. Quantitative remote sensing of land surfaces. New Jersey: J. Wiley, 2004. 560 p.
- LILLESAND, T.; KIEFER, R.W. Remote Sensing and Image Interpretation. 3.ed. New York: John Wiley & Sons, 1994.
- LIMA, J. P. Modelo de decisão para a priorização de vias candidatas às atividades de manutenção e reabilitação de pavimentos. 167 p. Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2007.
- LOPES, O.A. Uso do GPR (Ground Penetrating Radar) em trechos de pavimentos da cidade universitária da UFRJ. 185p. Dissertação (Mestrado em Engenharia Civil). COPPE, Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2009.
- MACHADO, C.C.; SANTANNA, G.L.; CARVALHO, C.A.de; OLIVEIRA, R.J. Sistema de gerência de pavimentos de estradas florestais. In: 7º Simpósio Brasileiro sobre Colheita e Transporte Florestal, 2005, Vitória. p. 405-439.

- MALLAT, S. G. A. A theory for multiresolution signal decomposition: the wavelet representation. IEEE Transaction on Pattern analysis and Machine Intelligence, 1989. 11(7): p. 674-693.
- MARCON, A.F. Contribuição a desenvolvimento de um sistema de gerência de pavimentos para o estado de Santa Catarina. Tese (doutorado em engenharia). Instituto Tecnológico da Aeronáutica. São José dos Campos. 1996. 397 p.
- MARQUES, I.A.O. Metodologia para o gerenciamento de rodovias de baixo volume de tráfego. Dissertação (mestrado em engenharia de transporte). Instituto Militar de Engenharia. Rio de Janeiro. 2005. 110 p.
- MARQUES FILHO, O.; VIEIRA NETO, H. Processamento digital de imagens. Rio de Janeiro: Brasport, 1999. 321 p.
- MARQUES, S. G. Metodologia geofísica para contaminação por hidrocarbonetos - estudo de caso em posto de combustíveis. 98 p. Dissertação (Mestrado em Geociências). Instituto de Geociências, Universidade de São Paulo. São Paulo. 2007.
- MATHER, P. M. Computer processing of remotely-sensed images: an introduction. 3 ed. Chichester: John Wiley and Sons, 2004.
- MATLAB. Using MatLab Version 7.0 (2004). The MathWorks, Inc. Natick, MA.
- MENEZES, R. S.; MENEZES, M. S. S. Patologia e Terapia dos Revestimentos Betuminosos. Anais da 30ª Reunião Anual de Pavimentação. Salvador: ABPv, 1996. p. 1503-1516.
- MILLER, D. M. *et al.* Neural network classification of remote sensing data. Computers and Geoscience. v.21, n.3, p.377-386, Mar, 1995.
- MILTON, E.J. Principles of Field Spectroscopy. International Journal of Remote Sensing. 1987, Vol. 8, no. 12, 1807-1827.
- MISITI *et al.* Wavelet toolbox user's guide. Copyright The Math-works, Inc., New York. 1997.
- MOREIRA, M.A. Fundamentos do sensoriamento remoto e metodologia de aplicação. 3. ed. Viçosa: Ed. UFV, 2005. 320 p.
- MOREIRA *et al.* Caracterização da reflectância espectral de materiais urbanos com imagens do sensor HSS. In: XIII Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13, 2007, Florianópolis. Anais... São José dos Campos: INPE, 2007. Artigos, p. 6489-6496. CD-ROM.
- MOTTA, C.G.L. da. Sistema inteligente para avaliação de riscos em vias de transporte terrestre. Tese de Mestrado - Engenharia Civil - Universidade Federal do Rio de Janeiro. 2004. 120 p.
- NAKAHARA, S. M. Estudo do desempenho de reforços de pavimentos asfálticos em via urbana sujeita a tráfego comercial pesado. Tese (doutorado em engenharia de transportes). Universidade de São Paulo. São Paulo. 2005. 298 p.
- NASCIMENTO, D.M. Análise comparativa de modelos de previsão de desempenho de pavimentos flexíveis. Dissertação (mestrado em engenharia). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos. 2005. 144 p.
- NCHRP Automatic Pavement Distress Collection Techniques - A Synthesis of Highway Practice. Transportation Research Board. Washington, D.C. 2004. 94 p.

NUNES, R.V.L.N. Método de previsão de defeitos em estradas vicinais de terra com base no uso de redes neurais artificiais: trecho de Aquiraz - CE. Dissertação (Mestrado em Engenharia de Transporte). Universidade Federal do Ceará. Fortaleza. 2003. 114 p.

OLHOEFT, G. R. Geophysical detection of hydrocarbon and organic chemical contamination. In: Proceedings on application of geophysics to engineering and environment problem. Oakbrook. 1992. p. 587-595.

_____. Electrical, magnetic, and geometric properties that determine ground penetrating radar performance. In: Proceedings of GPR'98. Seventh international conference on ground penetrating radar. Kansas. 1998. p. 177-182

OLHOEFT, G. R.; Smith III, S.S. 2000. Automatic processing and modeling of GPR data for pavement thickness and properties: in GPR2000, Proc. of the 8th Int'l Conf. on Ground Penetrating Radar, Gold Coast, Australia, 22-25 May 2000, D. A. Noon, G. F. Stickley, and D. Longstaff, eds., SPIE vol. 4084, p. 188-193.

OLHOEFT, G.R.; SELIG, E.T. 2002. Ground penetrating radar evaluation of railway track substructure conditions. Proceedings of the Ninth International Conference on Ground Penetrating Radar, April 29- May 2, 2002, Santa Barbara, California. S Koppenjan & H Lee (Eds) Proc. SPIE, Vol 4758: p. 48-53.

PAGAMISSE, A. Discriminação de texturas pela transformada Wavelet. Tese (Doutorado em Matemática Aplicada). 100 p. Instituto de Matemática, Estatística e Computação Científica, Universidade Estadual de Campinas. Campinas. 2003.

PAIXÃO, M. S. G. *et al.* Análise do emprego do GPR para estimar o teor de umidade do solo a partir de um estudo na cidade de São Paulo. Revista Brasileira de Geofísica, São Paulo, v. 24, abr. / jun. 2006.

PAOLA, J.D.; SCHOWENGERDT, R.A. The effect os neural-network structure on a multispectral land-use/land-cover classification. Photogrammetric Engineering and Remote Sensing, v.63, n.5, p.535-544, Mai, 1997.

PATERSON, W.D.O. Road deterioration and maintenance effects: models for planning and management. John Hopkins Press. Baltimore, USA, 1987.

PEDRAZZI, T. B. Proposição de uma estratégia para alocação de recursos financeiros em atividades de manutenção e restauração de pavimentos flexíveis. 342 p. Dissertação (Mestrado em Engenharia Civil). Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Universidade Estadual de Campinas. Campinas: UNICAMP, 2004.

PEDRINI, H.; SCHWARTZ, W.R. Análise de imagens digitais: princípios, algoritmos e aplicações. São Paulo: Thomson Learning, 2008. 508 p.

PIARC Highway development and management series. The World Road Association. Paris and World Bank. Washington, DC, v. 1-7. 2006.

PINTO, S.; PREUSSLER, E. Pavimentação rodoviária - conceitos fundamentais sobre pavimentos flexíveis. Rio de Janeiro: COPIARTE, 2001. 259 p.

QUEIROZ, C.A.V. Modelos de previsão do desempenho para a gerência de pavimentos no Brasil. Brasília. GEIPOT, 1984. 336 p.

RIBEIRO, L.C.B. Correção de uma imagem para efeitos atmosféricos utilizando dados de radiossonda. 81p. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais. São José dos Campos: INPE, 1992.

RODRIGUES FILHO, O. S. (2006). Características de aderência de revestimentos asfálticos aeroportuários - Estudo de caso do Aeroporto Internacional de São

Paulo/Congonhas. 263p.Dissertação. Instituto Tecnológico da Aeronáutica. São José dos Campo, SP: ITA, 2006.

SAARENKETO, T. 1997. Using ground penetrating radar and dielectric probe measurements in pavement density quality control. Annual Meeting of the Transportation Research Board. Washington, DC. p. 34-41.

_____. Electrical properties of Road materials and subgrade soils and the use of ground penetrating radar in traffic infrastructure surveys. 127 p. Thesis (Doctor of Philosophy). Faculty of Science, Department of Geosciences, University of Oulu. 2006.

SANTOS, R. C. Classificação textural aplicada à cobertura do solo de uma bacia hidrográfica usando sensoriamento remoto. 153 p. Dissertação (Mestrado em Engenharia Civil). Universidade Federal do Rio de Janeiro. COPPE. 2002.

SANTOS, R.T. A análise da macrotextura de pavimentos através de processamento de imagens, usando transformada de Fourier. 99 p. Dissertação (Mestrado em Modelagem Matemática) - Departamento de Física Estatística, Universidade Regional do Noroeste do Estado do Rio Grande do Sul. Ijuí. 2008.

SANTOS JR, O.J. dos Análise de dados de instrumentação de túneis do metrô de São Paulo - uma abordagem por redes neurais. 160 p. Dissertação. Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos. 2006.

SENÇO, W. Manual de Técnicas de Pavimentação. São Paulo, Pini. 1997.

SHRP. Distress Identification Manual for the Long-Term Pavement Performance Studies. The Strategic Highway Research Program. National Academy of Science. Washington, D.C., 1993.

SILVA, O. F.; BOGGIONE, G. A.; FONSECA, L. M. G. Fusão de imagens de sensoriamento remoto utilizando a transformada wavelet haar. In: XIII Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13, 2007, Florianópolis. Anais... São José dos Campos: INPE, 2007. Artigos, p. 6175-6182. CD-ROM.

SILVA, R. D.; MINETTO, R. Transformadas Wavelets: teoria e aplicações em análise de imagens digitais. 59 p. Monografia (Graduação em Ciência da Computação) - Setor de Ciências Exatas, Universidade Federal do Paraná, Curitiba. 2005.

SKLANSKY, J. Image Segmentation and Feature Extraction. IEEE Transactions on Systems, Man, and Cybernetics. v. 13, n. 5, p. 907-916, 1978.

SMITH, R. E.; DARTER, M. I.; HALL, K. T.; RAUHUT, J. B. Distress Identification Manual for the Long-Term Pavement Performance Studies. Federal Highway Administration. DTFH61-85-C-0095, 1987.

SOUZA, A. M. Uso do GPR na geração de modelos estáticos 3D para o planejamento de lavra minerais pesados depositados em dunas eólicas. 123 p. Dissertação (Mestrado em Geodinâmica e Geofísica). Universidade Federal do Rio Grande do Norte. Natal: UFRN, 2008.

SOUZA, R. C. A.; KUX, H. J. H. Comportamento Espectral e Alvos Urbanos: simulação com as bandas espectrais do satélite CBERS. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12, 2005, Goiânia. Anais... São José dos Campos, SP: INPE, 2005. Artigos, p. 1099-1106. CD-ROM.

SPETCH, L. P. Avaliação da macrotextura de pavimentos através do ensaio de mancha de areia. Teoria e prática na engenharia civil. n. 8, p. 53-62, abr. 2006.

STAENZ, K; ITTEN, K. I. Reflective properties of asphalt and concrete surfaces. Proceedings of the international symposium of the ISPRS. WG-VII. Toulouse, France, p. 307-316. 1982.

STEFFEN, C. A.; MORAES, E. C.; GAMA, F. F. Radiometria Óptica Espectral. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 8, 1996, Salvador. Anais... São José dos Campos, SP: INPE, 1996.

SUBIRATS, P.; DUMOULIN, J.; LEGEAY, V.; BARBA, D. Automation of pavement surface crack detection with a matched filtering to define the mother wavelet function used. In: Conference International IEEE, 2006, Atlanta. p. 3037-3040.

UFSC-CTC-INE. Disponível em www.inf.ufsc.br/~visao/2000/Wavelets/index.html. Acesso em: 16 abr. 2007.

UOL. Contas Abertas. Disponível em www.contasabertas.uol.com.br/noticias/detalhesnoticias.asp?auto=1278. Acesso em: 25 mar. 2008.

VENTURIERI, A.; SANTOS, J.R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. Sistema de Informações Geográficas: aplicações na agricultura. 2. ed. Ver. Ampl. Brasília: Embrapa-SP: Embrapa-CPAC, 1998.

VIEIRA, C. A. O. Accuracy of Remotely Sensing Classification of Agricultural Crops: a Comparative Study. 2000. 327 p. Thesis (Doctor of Philosophy). University of Nottingham. 2000.

VISCONTI, T.S. O sistema gerencial de pavimentos do DNER. Rio de Janeiro: DNER/IPT/Divisão de Apoio Tecnológico, 2000. 84 p.

XAVIER NETO, P. Processamento e interpretação de dados 2D e 3D de GPR: aplicações no imageamento de feições cársticas Tese (Doutorado em Geofísica). Centro de Ciências Exatas e da Terra, Universidade Federal do Rio Grande do Norte. Natal. 2006.

YSHIBA, J.K. Modelo de desempenho de pavimentos: estudo de rodovias do estado do Paraná. Tese (doutorado em engenharia). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2003. 222 p.

YSHIBA, J.K.; FERNANDES JUNIOR, J.L. Modelos estatísticos para previsão de desempenho de pavimentos. Acta Scientiarum Technology, Maringá, v. 27, n. 2, p. 175-181, jul./dez. 2005.

BIBLIOGRAFIA CONSULTADA

- ALBUQUERQUE, M.P.; ALBUQUERQUE, Marcelo Portes de. Processamento de imagens: métodos e análises. Rio de Janeiro: Editora da FACET, 2001 (Revista Científica).
- APS, M.; BALBO, J. T.; SEVERI, A. A. Avaliação superficial de pavimentos asfálticos em vias urbanas utilizando o método do PCI. In: Reunião Anual de Pavimentação, 31., 1998, São Paulo.
- ARONOFF, S. Geographical Information Systems: a management perspective. Ottawa. WDI Publications, 1989.
- BALBO, J. T. Pavimentos Asfálticos: patologias e manutenção. São Paulo: Plêiade, 1997. 103 p.
- BURROUGH, P. A.; MCDONNELL, R. A. Principles of Geographical Information Systems. Spatial Information Systems and Geostatistics. Oxford University, Oxford, 1998.
- DUDA, R.O.; HART, P.E.; STORK, D.G. Pattern classification. New York: Wiley, 2001. v. 2, 654 p.
- FLETCHER, D.; GOSS, E. Forecasting with neural networks: an application using bankruptcy data. Information and Management, v. 24, p. 159-167. Haralick, R. M., 1979, Statistical and structural approaches 1993.
- HARALICK, R.M. Statistical and structural approaches to texture. Proc. of IEEE, v. 67(5), p. 768-804. 1979.
- JAVIS, C.H.; STUART, N. The sensitivity of a neural network for classifying remotely sensed imagery. Computers and Geoscience, v.22, n.9, p.959-967, Nov. 1996.
- OHANIAN, P.P.; DUDES, R.C. Performance evaluation for four classes of textural features. Pattern Recognition, v. 25. n. 8, p 819-833. 1992.
- OLIVEIRA, J.A. Classificação de regiões usando atributos de forma e seleção de atributos. Dissertação (Mestrado em Sensoriamento Remoto). São José dos Campos, INPE, 2006.
- RENNÓ, C.D. Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens SIR-C/X-SAR do perímetro irrigado de Bebedouro, Petrolina, PE. 111 p. Dissertação (Mestrado em Sensoriamento Remoto). São José dos Campos, INPE, 2003.
- RUSSAN, K.; ROSS, N. F. The depth of rain water on road surfaces. Road Research Laboratory, Ministry of Transport Report N° LR236. 1998. 25 p.
- SILVA, P. F. A. Manual de patologia e manutenção de pavimentos. São Paulo: Pini, 2005. 114 p.
- SHIRAKAWA, T. *et al.* Application of the second generation wavelet transform for (2005). v. 6. p. 1113-1122. Disponível em: http://www.stage.jst.go.jp/article/easts/6/0/6_1113/_article. Acesso em: 30 abr. 2008.
- STRAND, J.; TAX, T. Local frequency features to texture classification. Pattern Recognition, v. 27. n. 10, p 1397-1406. 1994.

APÊNDICE A

PASSO-A-PASSO PARA CLASSIFICAÇÃO SUPERVISIONADA UTILIZANDO O SOFTWARE IDRISI ANDES

Neste apêndice será apresentando um passo-a-passo para se fazer uma classificação supervisionada com os classificadores MaxVer e RNA, utilizando o *software Idrisi Andes*, descrita em três passos.

A.1 PASSO 1

Independente de qual classificador utilizar, o primeiro procedimento para uma classificação supervisionada é obter as assinaturas das bandas consideradas e que serão usadas na classificação. Isso é feito através do comando *makesig* (Image Processing>Signature Development>MAKESIG) - Figura A.1.




Figura A.1 - Acesso ao comando **MAKESIG**, para assinatura das bandas

Os dados de entrada são a imagem de referência e os nomes das classes que serão classificadas.

Como exemplo, utilizou-se a imagem sintética na subseção 4.6.2.2 - Capítulo 4 (Figura 4.21). Essa imagem contém quatro bandas e quatro classes. A imagem de referência utilizada é a da Figura 4.22, também na subseção 4.6.2.2.

A Figura A.2 apresenta a tela do comando *makesig* e as devidas

explicações. Inicialmente, marcar a opção “Image” (1). Após, carregar a imagem de referência, clicando em (2). Em seguida, clicar em (3) para informar o nome das assinaturas e, em (3a) escrever o nome das classes que serão analisadas; clicar no botão “ok” para voltar à tela anterior (3b). Em *Number of files* (4) definir o número de bandas da imagem. Agora, na janela *Bands to be processed* clicar em (5) e carregar as bandas. Em (6) definir o número mínimo de amostras por classe para, finalmente, clicar no botão “ok” (7).




Figura A.2 - Tela do comando MAKESIG

O relatório das assinaturas das bandas, por classe, arquivo makesig_EMReport.id\$, encontra-se na Figura A.3.

MAKESIG Report:

Class ID	Class name	Sample size	Reqired min. Size	Meet min. size
1	aa	326327	90	yes
2	bb	330126	90	yes
3	cc	60802	90	yes
4	dd	69177	90	yes

Figura A.3 - Relatório das assinaturas das 4 bandas utilizadas

A.2 PASSO 2

Em seguida, descreve-se a classificação de imagem pelo método da Máxima Verossimilhança.

Utiliza-se o comando *maxlike* (Image Processing>Hard

Classifiers>MAXLIKE) - Figura A.4.




Figura A.4 - Acesso ao comando *maxlike*, para a classificação MaxVer

Após, na janela *MAXLIKE - maximum likelihood classification* (Figura A.5), configurar os parâmetros conforme sequência. Inicialmente, selecionar *Use equal prior probabilities for each signature*, para informar que as classes têm iguais probabilidades na classificação. Em seguida, definir o *Number of files*, que equivale ao número de arquivos de assinatura. Após preencher a janela *Signature to use in classification*, indicando as assinaturas definidas na Etapa 1. Em *Output image*, informar o nome do arquivo resposta. Finalmente, clicar em ok.




Figura A.5 - Tela do comando *maxlike* e informações sobre a entrada e saída dos dados

Após o comando, o resultado vem em forma de uma imagem classificada, com as classes rotuladas - Figura A.6, sendo "aa" o RA com alta deterioração, "bb" o RA com baixa deterioração, "cc" o RA novo e bom e "dd" o RA velho e bom.




Figura A.6 - Imagem classificada e rotulada

Para encerrar, o passo seguinte é fazer a avaliação da imagem classificada, comparando-a com a imagem de referência. Isso é feito através do comando *errmat* (Image Processing>Accuracy Assessment>ERRMAT) - Figura A.7.




Figura A.7 - Acesso ao comando **ERRMAT**, para avaliação da imagem classificada

Ciclando em **ERRMAT** aparece a tela conforme Figura A.8, na qual em *Ground truth image* se coloca a imagem de referência e em *Categorical map image*, informa-se nome da imagem classificada pelo comando MAXLIKE.




Figura A.8 - Tela do comando **ERRMAT** e informações sobre a entrada de dados

Para finalizar, tem-se a Tabela A.1 com a resultado de uma avaliação de

uma imagem classificada pelo algoritmo MaxVer.

Tabela A.1 - Matriz de erros da classificação MaxVer

MATRIZ DE ERROS							
Classe	1	2	3	4	Total	Correto(%)	E.C.(%)
1	326327	0	0	466	326793	99,86	0,14
2	0	60791	2446	0	63237	96,13	3,87
3	0	3	66731	2004	68738	97,08	2,92
4	0	8	0	327656	327664	100,00	0
Total	326327	60802	69177	330126	786432		
E.O.(%)	0	0,02	3,54	0,75			

Na próxima seção abordam-se as explicações sobre o uso do RNA no *software Idrisi Andes*.

A.3 PASSO 3

Nesta seção, descreve-se a classificação supervisionada de imagem usando RNA. Para tanto se acessa o comando *MLP* (Image Processing>Hard Classifiers>MLP) - Figura A.9.




Figura A.9 - Acesso ao comando MAXLIKE, para a classificação usando RNA

Ao clicar no comando MLP abre a janela, conforme Figura A.10, cujas explicações seguem abaixo:

1) Área *Classification options* - marcar se vai fazer o treinamento da rede (*Train network*) ou usar arquivo com pesos já determinados (*load weights*).

2) Área *Band images* - nessa área é onde se insere as bandas da imagem que será classificada, definindo o número de bandas (*number of files*). A inserção das bandas é feita na coluna *Image name*.

3) Área *Training site specification* - é aqui o local de entrar com a amostra de treinamento, que pode ser uma imagem ou um vetor. Define-se, também, o número de amostras de treinamento por classe (*Training pixels per category*) e o número de amostras de teste por classe (*Testing pixels per category*)




Figura A.10 - Tela do comando *MLP*

4) Área *Network topology* - inicialmente indicar o número de camadas ocultas (*Hidden layers*) e o número de neurônios por camadas (*Layer 1 nodes* e *Layer 2 nodes*). Por padrão, o número de neurônios na camada de entrada é

igual ao número de imagens de entrada. O número de neurônios da camada de saída depende do número de classes definidas na amostra de treinamento.

5) Área *Training parameters* - especificar os parâmetros de treinamento, sendo a taxa de aprendizagem (learning rate) o mais importante entre todos. Recomenda-se para iniciar com a taxa de treinamento entre 0,01 e 0,2. Outra opção é ajustar automaticamente a taxa de aprendizagem durante o treinamento, marcando a opção Use automatic training. Se selecionar Use dynamic learning rate entrar com o valor inicial e final da taxa de aprendizagem. Quanto ao Momentum factor recomenda-se seu valor entre 0,5 e 0,6. A função sigmoideal constante (Sigmoideal constant a:) pode ser ajustada, sendo o valor positivo o que determina a forma da curva sigmoideal e o gradiente da função de ativação.

6) Área *Stopping criteria* - para controlar os critérios de parada do treinamento da rede. O primeiro é a taxa de erro aceitável, baseado na convergência do erro médio quadrático (RMS). Pode-se também especificar o número de ciclos para finalizar o treinamento (Iterations). Outra possibilidade é definir uma taxa de exatidão, que sendo atingida, finaliza o treinamento (Accuracy rate). Finalmente, pode-se utilizar o botão Stop, localizado no canto inferior esquerdo da janela.

7) Área *Output options* - para definir como será apresentado os resultados da classificação. Se a classificação normal, marcar Hard classification; se é mostrar a matriz de confusão (que usa dados de validação para o treinamento), marcar Perform confusion matrix analysis; se selecionar Map output activation levels ou Map hidden layer activation é criado um prefixo na imagem classificada e um prefixo na(s) camada(s) oculta(s).

(8) Área *Output file names* - colocar o nome da imagem classificada em Hard classification image.

9) Botões *Train*, *Stop*, *Saveweights*, *Classify* e *Cancel* - respectivamente, para iniciar o treinamento da rede, para parar o treinamento da rede, para salvar os pesos dos neurônios após o treinamento da rede, para fazer a classificação com a rede já treinada e cancelar o treinamento.

10) Área *Running statistics* - para acompanhar os resultados dos parâmetros da rede, além do número de ciclos.

Definido a topologia da rede e feito o seu treinamento, a etapa seguinte é fazer a classificação da imagem. Inicialmente, marca-se opção *Perform confusion matrix analysis* para que haja uma análise dos resultados da classificação. Em seguida, clica-se no botão *Classify* para iniciar a classificação da imagem baseada na rede neural treinada.

Para finalizar essa seção, apresenta-se a Tabela A.2 com a resultado de uma avaliação de uma imagem classificada pelo algoritmo RNA.

Tabela A.2 - Matriz de erros da classificação usando RNA

MATRIZ DE ERROS							
Classe	1	2	3	4	Total	Correto(%)	E.C.(%)
1	325150	0	0	1177	326327	99,64	0,36
2	0	60665	6	131	60802	99,67	0,23
3	0	2480	66693	4	69177	96,41	3,59
4	1675	43	2004	326404	330126	98,87	1,13
Total	326825	63188	68703	327716	786432		
E.O.(%)	0,51	3,99	2,93	0,40			

APÊNDICE B

ROTINAS DESENVOLVIDAS NO SOFTWARE MATLAB

Neste apêndice apresentam-se duas rotinas desenvolvidas no *software* MatLab 7.0 e que foram utilizadas nos experimentos dos Capítulos 5 e 6 dessa tese.

A primeira rotina tem por finalidade determinar os coeficientes *Wavelets* das sub-bandas de alta frequência (3 sub-bandas), nível 1 de decomposição, aplicando *Daubechies 4*, em blocos quadrados, de ordem definido pelo usuário. Em seguida, calcula o vetor de característica de cada bloco da imagem, formado por: a) o maior valor do índice ICW (Equação 5.15); b) a média do brilho de cada bloco. Os vetores são gerados e usados na montagem de uma matriz $m \times n$, onde m equivale ao número de blocos da imagem e $n=2$.

O programa fonte da rotina está listado a seguir.

```
% Esta rotina calcula: 1) os coeficientes wavelets das 3 sub-bandas de
% alta frequencia na multirresolução wavelet (1 nível e daubichies 4)
% de imagens;2)o índice "icw" das sub-bandas; 3)o maior valor do "icw"
% das sub-bandas;4)a média do brilho do bloco.
% Utiliza janelas (blocos) definidas pelo usuário.
% OBS: O TAMANHO DO BLOCO TEM QUE SER MÚLTIPLO DAS LINHAS E COLUNAS DA
% IMAGEM

% Apresenta como resultado:
% 1) "Vetor linha" (vc2) - NE=2*(NC/TB)* NL/TB
% 2) "Matriz resposta" (resp)- NCM=2*(NC/TB), NLM=NL/TB
% 3) "Vetores de características (2 colunas x total de blocos)- vcp
% NE=num.elementos, NC=num.colunas da imagem, TB=tamanho bloco,
% NL=num.linhas da imagem, NCM=num.colunas da matriz resposta,
% NLM=num.linhas da matriz resposta

function [b] = enarmed2(jan)
imagem=input('Nome da imagem (entre apóstrofe e extensão): '); % en-
trar imagem de 8 bits
a=imread(imagem);
imagesc(a); % mostra a imagem lida
[tl tc] = size(a); % calcula o número de linhas (tl) e colunas (tc)
% da imagem
jan=input('Tamanho do bloco(janela): '); % tamanho da janela
ad=double(a); % a função wavelet exige que a imagem tenha precisão
% dupla

% Cálculo da "MATRIZ COLUNA", com NC=DMCW, NL=3*DMCW*NB
```

```

% (matriz com num. col. = dim. matriz coef. wavelets na subbanda)
vc2=[ ];
nf=1;
while nf<=fix(tl/jan)
    n=1;
    z=1;
    while n<jan*fix(tc/jan) %esse loop é para 1 faixa de tamanho
% "jan"
        k=0;
        for i=jan*nf-(jan-1):jan*nf %esse loop é para 1 bloco de
% tamanho "jan"
            t=0;
            k=k+1;
            for j=n:(jan-1+n)
                t=t+1;
                b(k,t)=ad(i,j);
            end
        end
        [c,s]=wavedec2(b,1,'db4'); % mutidecomposição, nível 1,
% daubechies 4
        ca=appcoef2(c,s,'db4',1); % extração coef.de aproximação
        ch1=detcoef2('h',c,s,1); % extração coef. horizontal
        cv1=detcoef2('v',c,s,1); % extração coef. vertical
        cd1=detcoef2('d',c,s,1); % extração coef. diagonal

        % CÁLCULO DO MAIOR "ICW" DA SUB-BANDA (icw)
        % cálculo da ICW da sub-banda horizontal
        ch=ch1.^2;
        chs=sum(ch);
        chst=chs';
        ch=sum(chst);
        [tlh tch]=size(ch1);
        ech1=tch*tlh; % calcula o número de elementos da sub-banda ch1
        ech=sqrt((1/ech1)*ch); % ICW da sub-banda ch1
        % cálculo da ICW da sub-banda vertical
        cv=cv1.^2;
        cvs=sum(cv);
        cvst=cvs';
        cv=sum(cvst);
        [tlv tcv]=size(cv1);
        ecv1=tcv*tlv; % calcula o número de elementos da sub-banda cv1
        ecv=sqrt((1/ecv1)*cv); % ICW da sub-banda cv1
        % cálculo da ICW da sub-banda diagonal
        cd=cd1.^2;
        cds=sum(cd);
        cdst=cds';
        cd=sum(cdst);
        [tld tcd]=size(cd1);
        ecd1=tcd*tld; % calcula o número de elementos da sub-banda cd1
        ecd=sqrt((1/ecd1)*cd); % ICW da sub-banda cd1
        tot=[ech ecv ecd];
        icw=max(tot);

        % CÁLCULO DA MÉDIA DO BRILHO DO BLOCO DA MATRIZ
        slb=mean(b);
        slbt=slb';
        st=mean(slbt); % média do brilho do bloco

        [b2 b1]=size(ch1);
        vc1=[icw st];
        n=n+jan;

```

```

        z=z+b1;
        vc2=[vc2 vc1];
    end
    nf=nf+1;
end

% MONTANDO A RESPOSTA
a=1;
for i=1:tl/jan
    for j=1:2*(tc/jan)
        resp(i,j)=vc2(1,a);
        a=a+1;
    end
end

dlmwrite('vc2.txt',vc2,' ');
dlmwrite('resp.txt',resp,' ');

% MONTA A MATRIZ DE 2 COLUNAS A PARTIR DA MATRIZ DO VETOR DE
% CARACTERISTICAS
tcvc=size(resp,2) % calcula o número de colunas do vetor de
% característica vc
tlvc=size(resp,1); % calcula o número de linhas do vetor de
% característica vc
a=tcvc/2;
s=1;
p=0;
r=1;
while s<=tlvc
    k=1;
    for i=1:a
        for j=1:2
            vcp(i+p,j)=resp(r,k); % matriz de 2 colunas X
            % número de blocos
            k=k+1;
        end
    end
    p=p+a;
    r=r+1;
    s=s+1;
end
dlmwrite('vcp.txt',vcp,' ');

```

A segunda rotina é uma implementação da primeira rotina, acrescentando a classificação por limiarização dos dois extratores: ICW e média do brilho de cada bloco. Fornece como resultado uma imagem binária, cuja menor unidade é o bloco 4x4, apresentando uma visualização “blocada”.

O programa fonte da rotina está listado a seguir.

```

% Esta rotina calcula: 1) os coeficientes wavelets das 3 sub-bandas de
% alta frequencia na multirresolução wavelet (1 nível e daubichies 4)
% de imagens;2)a energia das sub-bandas; 3)o maior valor da energia
% das sub-bandas;4)a média do brilho do bloco
% ATUALMENTE SÓ ESTÁ IMPLEMENTADA PARA BLOCOS DE DIMENSÃO 4!!!!

```

```

% Apresenta como resultado:
% 1) "Matriz resposta" (resp)- NC=2*(NC/TB), NC=NL/TB
% 2) "Matriz equivalente" (eq) - matriz com uns e zeros substituindo
% cada bloco
% 3) "Matriz imagem" (imag) - imagem classificada
% NE=num.elementos, NC=num.colunas, TB=tamanho bloco, NL=num.linhas

function [b] = classem(jan)
imagem=input('Nome da imagem (entre apóstrofe e extensão): ');
% entrar imagem de 8 bits
a=imread(imagem);
imagesc(a); % mostra a imagem lida
[tl tc] = size(a); % calcula o número de linhas (tl) e colunas
% (tc) da imagem
jan=input('Tamanho do bloco(janela): '); % tamanho da janela
lim1=input('Valor do limiar para a energia: ');
lim2=input('Valor do limiar para a media do brilho: ');
ad=double(a); % a função wavelet exige que a imagem tenha precisão
% dupla

vc2=[ ];
nf=1;
while nf<=fix(tl/jan)
    n=1;
    z=1;
    while n<jan*fix(tc/jan) %esse loop é para 1 faixa de
% tamanho "jan"
        k=0;
        for i=jan*nf-(jan-1):jan*nf %esse loop é para 1 bloco de
% tamanho "jan"
            t=0;
            k=k+1;
            for j=n:(jan-1+n)
                t=t+1;
                b(k,t)=ad(i,j); % bloco para ser analisado
            end
        end
        n=n+1;
    end

    % CÁLCULO DOS COEFICIENTES WAVELETS DO BLOCO (SUB-BANDAS)
    [c,s]=wavedec2(b,1,'db4'); % mutidecomposição, nível 1,
% daubechies 4
    ca=appcoef2(c,s,'db4',1); % extração coef.de aproximação
    ch1=detcoef2('h',c,s,1); % extração coef. horizontal
    cv1=detcoef2('v',c,s,1); % extração coef. vertical
    cd1=detcoef2('d',c,s,1); % extração coef. diagonal

    % CÁLCULO DO MAIOR VALOR DE ICW
    % cálculo do ICW da sub-banda horizontal
    ch=ch1.^2;
    chs=sum(ch);
    chst=chs';
    ch=sum(chst);
    [tlh tch]=size(ch1);
    ech1=tch*tlh; % calcula o número de elementos da sub-banda ch1
    ech=sqrt((1/ech1)*ch); % ICW sub-banda ch1
    % cálculo do ICW da sub-banda vertical
    cv=cv1.^2;
    cvs=sum(cv);
    cvst=cvs';
    cv=sum(cvst);
    [tlv tcv]=size(cv1);

```

```

ecv1=tcv*tlv; % calcula o número de elementos da sub-banda cv1
ecv=sqrt((1/ecv1)*cv); % ICW da sub-banda cv1
% cálculo do ICW da sub-banda diagonal
cd=cd1.^2;
cds=sum(cd);
cdst=cds';
cd=sum(cdst);
[tld tcd]=size(cd1);
ecd1=tcd*tld; % calcula o número de elementos da sub-banda cd1
ecd=sqrt((1/ecd1)*cd); % ICW da sub-banda cd1
tot=[ech ecv ecd];
icw=max(tot);

% CÁLCULO DA MÉDIA DO BRILHO DO BLOCO DA MATRIZ
slb=mean(b);
slbt=slb';
st=mean(slbt); % média do brilho do bloco

% MONTANDO A RESPOSTA (cada 2 elementos substitui o bloco)
% vetor linha resposta (vc2)
[b2 b1]=size(ch1);
vc1=[icw st];
n=n+jan;
z=z+b1;
vc2=[vc2 vc1];
end
nf=nf+1;
end

% matriz resposta (resp)
a=1;
for i=1:tl/jan
    for j=1:2*(tc/jan)
        resp(i,j)=vc2(1,a);
        a=a+1;
    end
end
dlmwrite('resp.txt',resp,' ');

% ANALISANDO OS VALORES ENERGIA E BRILHO
[b3 b4]=size(resp);
for i=1:b3
    for j=1:2:b4
        if resp(i,j)>lim1 & resp(i,j+1)<lim2
            eq(i,j)=0; % imprime "zero" quando atende aos limiares
            eq(i,j+1)=0; % imprime "zero" quando atende aos limiares
        elseif resp(i,j)<lim1 & resp(i,j+1)>lim2
            eq(i,j)=1; % imprime "um" quando não atende aos limiares
            eq(i,j+1)=1; % imprime "um" quando não atende aos limiares
        else
            eq(i,j)=1; % imprime "um" quando não atende aos limiares
            eq(i,j+1)=1; % imprime "um" quando não atende aos limiares
        end
    end
end
dlmwrite('eq.txt',eq,' ');

% REMONTANDO A IMAGEM CLASSIFICADA (imagem blocada)
h=1;
[a b]=size(eq);
for i=1:a

```

```

n=1;
for j=1:2:b
    imag(h,n)=eq(i,j);
    imag(h,n+1)=eq(i,j);
    imag(h,n+2)=eq(i,j);
    imag(h,n+3)=eq(i,j);
    imag(h+1,n)=eq(i,j);
    imag(h+1,n+1)=eq(i,j);
    imag(h+1,n+2)=eq(i,j);
    imag(h+1,n+3)=eq(i,j);
    imag(h+2,n)=eq(i,j);
    imag(h+2,n+1)=eq(i,j);
    imag(h+2,n+2)=eq(i,j);
    imag(h+2,n+3)=eq(i,j);
    imag(h+3,n)=eq(i,j);
    imag(h+3,n+1)=eq(i,j);
    imag(h+3,n+2)=eq(i,j);
    imag(h+3,n+3)=eq(i,j);
    n=n+4;
end
h=h+4;
end
dlmwrite('imag.txt',imag,' ');

```

APÊNDICE C

PASSO-A-PASSO PARA PROCESSAMENTO DE IMAGENS DO GPR COM O USO DO SOFTWARE GRADIX

Neste apêndice será apresentada a sequência de operações para se fazer o processamento dos dados do GPR, utilizando o *software* GRADIX, versão 1.1, da empresa Interpex Limited.

Inicialmente, os arquivos do GPR (extensão “dzt”) foram transferidos para o computador. Ao iniciar o *software* GRADIX aparece a tela de abertura - Figura C.1. Para continuar, pressionar qualquer tecla.



Figura C.1 - Tela de abertura do GRADIX

A próxima tela que aparece está apresentada na Figura C.2. Nesta tela estão os vários menus disponíveis do *software*.



Figura C.2 - Tela dos menus do GRADIX

Antes de iniciar o processamento das imagens, a primeira providência é criar um projeto, através da opção *input>Create project*. Na tela *Set Project*

(Figura C.3), em *FILE LOCATION>Dir*, informar a pasta na qual se encontram os arquivos que serão importados. Em *FILE LOCATION>File* informar o nome que será dado aos arquivos que serão importados para processamento no GRADIX. Clicar no botão “ok”.




Figura C.3 - Tela para criar o projeto e definir o nome que será dado aos arquivos importados para o GRADIX

A próxima tela é a *Radar Field File Import* - Figura C.4. É onde informamos sobre o formato dos arquivos que serão importados e as características dos arquivos de saída, tais como, formato, unidade, marcas de distância, extensão, etc. Escolhidas as opções, clicar no botão “ok”.




Figura C.4 - Tela de importação de dados do GPR e escolha das características do dados de saída, que serão processados no GRADIX

A tela seguinte - Figura C.5 (a) é para selecionar a pasta na qual estão os arquivos que se queira importar para o GRADIX. Após a seleção, clicar no botão “ok”. A figura C.5 (b) mostra os arquivos que estão na pasta selecionada anteriormente. Agora, basta fazer a seleção dos arquivos de interesse e, se forem todos, clicar no botão “all”. Após, clicar no botão “ok”.




Figura C.5 - Tela para escolher os arquivos que serão importados para o GRADIX
(a) - escolha da pasta; (b) - escolha dos arquivos

Agora, na tela *Radar Geometry* - Figura C.6, na coluna *First Northing*, dar um incremento para cada arquivo (normalmente 5). Clicar iniciar a importação dos dados, clicar no botão “ok”. Os arquivos importados passarão a ter a extensão “prj”, que é a extensão do GRADIX.

Field Filename	Line Num	File Num	First Easting	First Northing	Last Easting	Last Northing	Station Inc	Line Angle
FILE_1	1	1	0.00	5	38.85	5.00	0.005	90
FILE_2	2	1	0.00	10	58.93	10.00	0.005	90
FILE_3	3	1	0.00	15	57.57	15.00	0.005	90
FILE_4	4	1	0.00	20	48.95	20.00	0.005	90
FILE_5	5	1	0.00	25	8.53	25.00	0.005	90
FILE_6	6	1	0.00	30	47.25	30.00	0.005	90
FILE_7	7	1	0.00	35	22.17	35.00	0.005	90
FILE_8	8	1	0.00	40	34.47	40.00	0.005	90
FILE_9	9	1	0.00	45	5.28	45.00	0.005	90
FILE_10	10	1	0.00	50	55.94	0.00	0.005	90

Figura C.6 - Tela sobre informação dos dados que serão importados para o GRADIX

Até aqui se criou um projeto e fez-se a importação dos dados (imagens) do GPR para processamento no GRADIX. Os passos seguintes discorrem sobre a leitura das imagens e o seu processamento.


Para abrir um arquivo, inicialmente deve-se abrir o projeto nomeado e selecionar o arquivo dentro do projeto. Para tanto, clicar em *input>Open Project*, informar a pasta (na opção *Dir:*) e o nome do arquivo (na opção *File:*).

Pode-se, também, usar o botão “Browse” para chegar ao arquivo que será lido - Figura C.7 (a). Clicar no botão “ok”.

A Figura C.7 (b) apresenta a tela denominada *Project Map*, que mostra os arquivos que fazem parte do projeto. Escolher um dos arquivos e clicar com o mouse sobre ele e, em seguida, clicar no botão “ok”.



(a)




(b)

Figura C.7 - Telas para leitura dos arquivos no GRADIX
(a) - informar nome do projeto e arquivo; (b) - selecionar com o mouse o arquivo

Agora já é possível visualizar o radargrama (imagem do GPR). Para tanto clicar em *View>Profile* - Figura C.8. (a). Na Figura C.8 (b) apresenta a imagem de um radargrama, correspondente a um perfil sub-superficial levantado com o uso do GPR.



(a)



(b)


Figura C.8 - Telas para visualização dos arquivos no GRADIX
(a) - menu para acessar o arquivo; (b) - visualização do arquivo (radargrama)

Com o arquivo lido, passa-se à etapa do seu processamento, seguindo os passos descritos a seguir.

Para iniciar, utiliza-se o comando *Declip* (*aPply>deClip*), cuja função é restaurar, por interpolação, as formas das ondas dos primeiros ciclos e que são afetadas pela chegada da onda direta do ar, com maior amplitude que a energia refletiva (SOUZA, 2008) - Figura C.9.



(a)




(b)

Figura C.9 - Telas do comando *declip*
(a) - tela de acesso ao comando; (b) - resultado após o uso do *declip*

Em seguida, utiliza-se o comando *Dewow* (*Analyze>deWow*) para remover os componentes de baixa frequência originados de fenômenos indutivos relacionados com a saturação na imagem, originada pela onda direta (propagada no ar) ou por limitações dinâmicas do GPR (SOUZA, 2008) - Figura C.10.



(a)




(b)

Figura C.10 - Telas do comando *dewow*
(a) - tela de acesso ao comando; (b) - resultado após o uso do *dewow*

O próximo passo é usar o comando *Set time zero* (*Analyze>set time Zero*), que tem por finalidade ajustar o tempo inicial de registro à primeira onda a chegar na antena receptora, que é caracterizada pela onda direta no ar (SOUZA, 2008) - Figura C.11.



(a)



(b)


Figura C.11 - Telas do comando *set time zero*

(a) - tela de acesso ao comando; (b) - resultado após o comando *set time zero*

Agora, usar o comando *Window Traces* (*Edit>Window Traces*), cuja função é cortar a parte superior do radargrama, eliminando o trecho acima do *set time zero* - Figura C.12.



(a)



(b)

Figura C.12 - Telas do comando *window traces*

(a) - tela de acesso ao comando; (b) - resultado após o comando *window traces*

O último passo é usar o comando *remove Background* (*Analyse>remove background*), utilizado para remover os “ruídos de fundo” da imagem e ressaltar os refletores na imagem - Figura C.13. Temos, então, a imagem processada.



(a)



(b)

Figura C.13 - Telas do comando *remove background*

(a) - tela de acesso ao comando; (b) - resultado após o comando *remove background*

Para encerrar esse passo-a-passo, o último comando a ser apresentado é para melhorar a visualização da imagem processada. A imagem apresentada na tela tem, via de regra, a escala horizontal extremamente menor que a escala vertical. É comum levantar-se perfis com várias dezenas de metros (valor horizontal) e com 50cm de profundidade (valor vertical). Assim, a imagem apresentada é completamente distorcida.

Para modificar a escala horizontal, clicar em *edit view*, após, clicar no botão que permite mudar a escala horizontal e, definir os novos parâmetros. A Figura C.14 apresenta um trecho de um radargrama com as escalas horizontal e vertical iguais, facilitando a interpretação da imagem.




Figura C.14 - Tela mostrando o radargrama com as escalas horizontal e vertical iguais

APÊNDICE D

EXEMPLO DE APLICAÇÃO USANDO O SOFTWARE HDM-4

O propósito dessa seção é apresentar um exemplo de aplicação usando o *software* HDM-4, mostrando sua potencialidade. O exemplo vai desde a definição da ferramenta de análise, passando pela criação do projeto, definindo os detalhes do projeto e as alternativas de análise para, finalmente, fazer a impressão dos relatórios do projeto.

Ao iniciar o HDM-4 abre a tela conforme Figura D.1 e pode-se escolher qual a ferramenta de análise será utilizada: Project Analysis, Programme Analysis ou Strategy Analysis.



Figura D.1 - Janela do HDM-4, para a escolha da ferramenta de análise

Por não ter sido possível conseguir dados de rodovias no Brasil para fazer as análises, será utilizado um exemplo do próprio manual do HDM-4 (PIARC, 2006) e escolheu-se, dentre vários exemplos, a análise de projeto da reabilitação de uma rodovia pavimentada. O projeto escolhido apresenta um estudo de caso da análise econômica de alternativas padrões de reabilitação de 2 seções típicas (segmentos homogêneos), escolhidas como representativas de todas as seções da via. Nessas seções passam de 12.500 a 40.000 veículos por dia e exibem moderados níveis de aderência e defeitos de superfície. São avaliadas várias alternativas futuras de reabilitação: uma fina camada para melhorar a aderência, uma camada estrutural e a reconstrução

total do pavimento.

As etapas da análise de projeto são: a) previsão de deterioração da via; b) estimativa de custos do usuário (custos de operação de veículos, tempo de viagem e acidentes); c) cálculo de benefícios econômicos através da comparação de alternativas do projeto.

A análise de projetos está associada com os seguintes tipos de projetos rodoviários: a) manutenção de vias existentes - cobre uma variedade de técnicas de manutenção para diferentes tipos de pavimentos; b) melhorias de vias existentes - ajudam a melhorar a capacidade da via quando esta chega próxima do final de sua vida; c) novas construções - envolve a construção de um novo pavimento em uma nova posição; d) estágio da construção - consiste no planejamento de melhorias no pavimento, fixando estágios ao longo de sua vida útil; e) avaliação de projetos executado - avalia o desempenho de projetos implantados para ver se seus objetivos iniciais foram contemplados.

Quanto aos métodos de análise, o HDM-4 disponibiliza dois métodos: a) análise por seção - cada seção selecionada da via é analisada separadamente, várias alternativas podem ser definida para cada seção (por exemplo, manutenção e/ou melhorias padrões) e são calculados índices econômicos para cada alternativa; b) análise por projeto - quando a análise (alternativas e índice econômicos) é feita sobre um conjunto de seções e não uma única seção separadamente.

Os passos para a análise de projetos são apresentados nas seções seguintes.

D.1 CRIAR UM NOVO PROJETO (NEW PROJECT)

Nesta etapa, cria-se um nome para o projeto e especifica-se a rede viária que será analisada - Figura D.2.



Figura D.2 - Janela do HDM-4 para nomear um novo projeto

D.2 DEFINIR OS DETALHES DO PROJETO (DEFINE PROJECT DETAILS)

Nesta etapa, define-se o seguinte: a) informações gerais sobre o projeto, aba *General*; b) seções de estudo, aba *Study Sections*.

Na Figura D.3 tem-se a janela da aba *General*, na qual ficam as informações gerais do projeto, tais como, sua descrição (*Description*), tipo de análise (seção ou projeto), ano inicial (*Start year*), período de análise (*Analysis period*), frota de veículos considerada (*Vehicle Fleet*), moeda corrente (*Currencies*), etc.




Figura D.3 - Aba *General*

Na Figura D.4 tem-se a aba *Study Sections*. A seleção individual das seções é feita clicando no *box* na coluna *Study* ou *Analysis*. A seção também pode ser selecionada através da área *Select by Criteria*, utilizando os seguintes critérios: a) pavement - Surface class (opções: all, Bituminous, Concrete or

Unsealead) ou Structural Adequacy (opções: all, one of the pre-defined categories); b) Speed Flow Type - opções: all, one of the pre-defined categories; c) Traffic Volume - opções: all, one of the pre-defined categories; d) Geometry - opções: Minimum and/or maximum values of Rise (subida) and Fall (descida) (m/km), Horizontal Curvature (deg/km) and Carriageway (faixas de rolamento) Width (m).

Uma pré-definição do crescimento do tráfego é introduzida no botão *Assign Growth Set ...* e assinalada para cada seção selecionada, aparecendo na coluna *Traffic Growth*.




Figura D.4 - Aba Study Sections

O botão *View/Edit Section ...* é para visualizar e editar as seções em estudo. Aqui são colocadas as informações sobre a definição, geometria, pavimento, condições, outros parâmetros, tráfego motorizado e parâmetros de validação de cada seção - Figura D.5.

O botão *View/Edit Network ...* é para visualizar e editar as redes (conjunto de seções) em estudo. As informações sobre a definição, geometria, pavimento, condições, outros parâmetros, tráfego motorizado e parâmetros de validação de cada rede são introduzidas da mesma forma que na explicação do parágrafo anterior.

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Name: V11 Traffic, Fair, 2 Lane
 ID: V11 Fair 2
 Link Name:
 Link ID:
 Length: 1 km
 Clear Width: 7 m
 Shoulder Width: 1 m
 Flow Direction: Two-way
 Surface Class: Bituminous

Speed Flow Type: Two Lane Road
 Traffic Flow Pattern: Free flow
 Accident Class: Two Lane Road
 Climate Zone: Tropical Humid
 Road Class: Primary or Trunk

Calibration Set: National
 Calibration Item: High traffic

Selected Calibration Item Summary
 Pavement type: Asphalt Mix on Asphalt Pavement
 Surface material: Asphalt Concrete

OK Cancel

Name of section:

(a)

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Speed Reduction Factors

Rise + Fall: 25 m/km
 No. of rises + falls: 2 no./km
 Super-elevation: 7.5 %
 Avg. horizontal curvature: 40 deg/km
 adiab: 0.1 m/s²
 Speed limit: 50 km/h
 Speed limit enforcement: 1.1
 Altitude: 0 m

Speed Reduction Factors

>BMT: 1 0.4 (<=>BMT) <= 1
 Road side friction: 1 0.4 (<=>RSE) <= 1
 >BMT: 1 0.4 (<=>BMT) <= 1

OK Cancel

Average road rise plus fall (in m/km):

(b)

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Pavement

Pavement type: Asphalt Mix on Asphalt Pavement
 Material type: Asphalt Concrete

Most recent surfacing thickness: 40 mm
 Previous old surfacing thickness: 160 mm

Previous works (RDM-4 Work Types)

Last reconstruction or new construction: 1996 year
 Last rehabilitation (pre-fall): 2003 year
 Last resurfacing (sealing): 2001 year
 Last preventative treatment: 2001 year

Strength

Calculated Dry season model parameters
 SNIP: 5.70 DEF: 0.40 mm
 (1) Structural Number: 4.7
 Subgrade CBR: 7.6 %
 Dry Season Wet Season
 Calculated SNIP: Calculate SNIP

Road base (for stabilised base only)

Base thickness: mm
 Proportional modulus: GPa

OK Cancel

Details of pavement construction:

(c)

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Condition at end of year: 2002

Roughness (IRI - m/km): 3.40
 All Structural Cracks (%): 2.80
 Wide Structural Cracks (%): 0.00
 Thermal Cracks (%): 0.00
 Rounded area (%): 0.00
 Number of potholes (No./km): 0.00
 Edge break area (m²/km): 0.00
 Mean rut depth (mm): 5.60
 Rut depth standard deviation (mm): 1.70
 Texture depth (mm): 0.70
 Skid resistance (ICFHM Skid-TR): 0.50
 Drainage: Excellent

OK Cancel

Yearly condition data:

(d)

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Separate NMT lanes

Number of lanes: 1

Shoulders (Concrete only)

Shoulder type: New concrete
 Width of shoulder: m

Drainage

Drain type: No change in drainage effect

Compaction (Bituminous only)

Relative compaction: 90 %

Previous surface condition (Bituminous only)

Area of all structural cracking: 0 %
 Area of wide cracking: 0 %
 Transverse thermal cracks: 0 no./km

LANES: 2

OK Cancel

Model separate lanes for non-motorised traffic:

(e)

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Vehicle fleet used for this section/yearbook: National Fleet

Survey Year: 2005

2-wheeled Truck: 4000.00
 3-wheeled Heavy Truck: 1400.00
 4-wheeled Artic: 1000.00
 Bus: 600.00
 Motor Car: 10000.00
 Motorcycles: 10000.00
 Utility van: 4000.00
 Total ADT: 40000.00

Edit Year...

OK Cancel

Motorised traffic:

(f)

Section: V11 Traffic, Fair, 2 Lane

Definition | Geometry | Pavement | Condition | Other | Motorised Traffic | Asset Valuation

Replacement cost: 0

Asset valuation method for Road Pavement Layers

Condition based Production based

Initial roughness: 2 IRI (m/km)
 Terminal roughness: 12 IRI (m/km)

Year asset component ages defined for: 0 year

Asset Component	Replacement cost (%)	Residual value of asset component (%)	Useful life of asset component	Age of asset component in year 0
Road formation and sub-grade	0.00	0.00	10,000.00 years	0.00 years
Road pavement layers	100.00	0.00	0.00 years	0.00 years
Footways, footpaths and cycleways (NMT lanes)	0.00	0.00	0.00 years	0.00 years
Bridges and structures	0.00	0.00	0.00 years	0.00 years
Traffic facilities, signs and road furniture	0.00	0.00	0.00 years	0.00 years

MEAL: Million Equivalent Standard Axle Loads, THSmm: Initial gravel thickness
 All costs are in Malaysian Ringgit

OK Cancel

Enter replacement cost for the complete section:

(g)

Figura D.5 - Opções do botão View/Edit Section
(a) - aba Definition; (b) - aba Geometry; (c) - aba Pavement; (d) - aba Condition; (e) - aba Other; (f) - aba Motorized Traffic; (g) - aba Asset Valuation

O botão *View/Edit Fleet ...* é para visualizar e editar dados sobre a frota de veículos - Figura d.6 (a). Selecionado na coluna *Name* um determinado veículo e clicando, em seguida, no botão *Edit*, obtém-se a janela de acordo com a Figura D.6 (b), com as opções *Definition*, *Basic Characteristics* e *Economic Unit Costs*, que são características do veículo.




Figura D.6 - Janelas de definição de dados sobre a frota de veículos
(a) - relação dos veículos que passam na via; (b) características do veículo

D.3 ESPECIFICAR ALTERNATIVAS (SPECIFY ALTERNATIVES)

Determinadas intervenções podem gerar tráfego adicional sobre a seção da via. As características do tráfego desviado e/ou gerado podem ser especificadas para cada intervenção. O método de especificar alternativas depende se a análise é por seção ou por projeto.

No estudo de caso apresentado são consideradas quatro alternativas, conforme Tabela D.1. A alternativa 1 é a básica, compreendendo rotinas de manutenção que inclui: reparo de bordas, remendo de panelas e remendo de áreas afetadas por trincas largas. Neste caso, uma reconstrução é aplicada ao pavimento se o IRI ultrapassar 10. As outras três alternativas incluem a mesma manutenção de rotina, com diferença na seção da manutenção periódica.

Tabela D.1 - Alternativas de manutenção

Alternativa	Itens de intervenção	Critério
1 Base Alternative	Reparo na borda	Quebra de borda > 1 m ² /km
	Remendo de panelas	Panelas > 1 unid/km
	Remendo de trincas largas	Largura trincas > 5%
	Reconstrução pavimento - 150 mm RA	IRI > 10
2 GAT03	Reparo na borda	Quebra de borda > 1 m ² /km
	Remendo de panelas	Panelas > 1 unid/km
	Remendo de trincas largas	Largura trincas > 5%
	Camada de 40 mm	3 < IRI < 5 Intervalo mínimo 5 anos
3 GAS04-5	Reparo na borda	Quebra de borda > 1 m ² /km
	Remendo de panelas	Panelas > 1 unid/km
	Remendo de trincas largas	Largura trincas > 5%
	Camada de 80 mm	4,5 < IRI < 6,5 Intervalo mínimo 7 anos
4 GAFR6	Reparo na borda	Quebra de borda > 1 m ² /km
	Remendo de panelas	Panelas > 1 unid/km
	Remendo de trincas largas	Largura trincas > 5%
	Reconstrução pavimento - 150 mm RA	IRI > 6

As quatro alternativas são mostradas na Figura D.7, correspondente as 2 seções analisadas.




Figura D.7 - Janela *Specify Alternatives*, mostrando à direita as 2 seções analisadas

D.4 ANÁLISE DE PROJETOS (ANALYSE PROJECTS)

Essa etapa é desenvolvida em 3 fases: *Run Setup*, *Sensitivity* e *Run Analysis*.

D.4.1 RUN SETUP

Aqui o usuário especifica os parâmetros que serão analisados - Figura D.8.

A opção *Conduct Economic Analysis* é marcada quando se pretende fazer uma análise econômica. Se a análise é por seção essa alternativa fica automaticamente selecionada e se a análise é por projeto essa alternativa é opcional. Para ambos os tipos de análise a taxa de desconto (*discount rate*) deve ser definida.

A opção *Accident Costs* é marcada somente se a análise de acidentes será feita.

A opção *Model Inclusion* é para incluir outros modelos na análise, como: balanço de energia (*energy balance*), emissões dos veículos (*emissions*) e efeitos da aceleração (*acceleration effects*).

A opção *Asset valuation* é opcional e estima o valor do recurso de uma rede que está sendo analisada durante o período de análise.




Figura D.8 - Janela da opção *Analyse Projects*, aba *Setup Run*

No exemplo em curso, os itens acidentes, balanço de energia, emissões de gases, efeitos da aceleração dos veículos e o valor do recurso não foram incluídos na análise.

D.4.2 SENSITIVITY

Se marcar a opção *Conduct Sensitivity Analysis* cenários de sensibilidade serão investigados, pela variação de qualquer dos 18 parâmetros que estão disponíveis. Fatores de ponderação são definidos para os parâmetros e, assim, determinado os efeitos sobre os resultados das análises - Figura D.9.




Figura D.9 - Janela da opção *Analyse Projects*, aba *Sensitivity*

No exemplo em curso, o item sensibilidade não foi incluído na análise.

D.4.3 RUN ANALYSYS

A análise do projeto é feita após a seleção do botão *Start* e o status do processamento é mostrado - Figura D.10. O presente exemplo durou 6 segundos para ser processado.




Figura D.10 - Janela da opção *Analyse Projects*, aba *Run Analysis*

D.5 ANÁLISE MULTICRITÉRIOS (MULTI CRITERIA ANALYSIS)

Pode-se escolher até 9 critérios (no mínimo 2) e após, clicar no botão *Start*. Os critérios disponíveis são: a) custos do usuário (Road user costs); b) valor presente líquido (net present valor); c) análise de acidentes (Accident analysys); d) conforto (Comfort); e) congestionamento (Congestion); f) poluição do ar (Air Pollution); g) eficiência energética (Energy efficiency); h) benefícios sociais (Social benefits); i) benefícios políticos (Political) - Figura D.11.




Figura D.11 - Janela da opção *Multi Criteria Analysis*, aba *MCA Setup*

No exemplo em curso, o item Análise Multicritério não foi incluído na análise.

D.6 RELATÓRIOS GERADOS (GENERATE REPORTS)

Os relatórios gerados pelo *software* HDM-4 ficam em 9 pastas e os resultados são apresentados em forma tabular ou, em alguns casos, no formato gráfico. As pastas têm os seguintes nomes: a) Traffic; b) Deterioration/Works Effects; c) Road User Effects; d) Environmental Effects; e) Cost Streams and Economic Evaluation; f) Programme & Strategy Analysis; g) Input Data; i) Multi Criteria Analysis; j) Asset Valuation.

Dentro de cada pasta tem vários arquivos que, sendo de interesse, deve ser selecionado e, em seguida, clica-se no botão *Generate Report...* para obter o relatório dos resultados desejados - Figura D.12.






Figura D.12 - Janela da opção *Generate Reports*

Por exemplo, a Figura D.13 (a) apresenta um resultado na forma tabular (resumo das intervenções na via, por ano) e na Figura D.13 (b) na forma gráfica (da irregularidade média ao longo dos anos).



(a)



(b)

**Figura D.13 - Exemplos dos relatórios apresentados pelo HDM-4
(a) - resultado na forma tabular; (b) - resultado na forma gráfica**