MARCOS RIBEIRO RESENDE

INVESTIGAÇÃO DO USO DE IMAGENS DE SENSOR DE
SENSORIAMENTO REMOTO HIPERESPECTRAL E COM ALTA
RESOLUÇÃO ESPACIAL NO MONITORAMENTO DA CONDIÇÃO DE
USO DE PAVIMENTOS RODOVIÁRIOS

São Paulo
2010

MARCOS RIBEIRO RESENDE

INVESTIGAÇÃO DO USO DE IMAGENS DE SENSOR DE
SENSORIAMENTO REMOTO HIPERESPECTRAL E COM ALTA
RESOLUÇÃO ESPACIAL NO MONITORAMENTO DA CONDIÇÃO DE
USO DE PAVIMENTOS RODOVIÁRIOS

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do grau de mestre
em Engenharia

Área de Concentração:
Engenharia de Transportes

Orientador:
Prof. Dr. José Alberto Quintanilha

São Paulo
2010

FICHA CATALOGRÁFICA

Resende, Marcos Ribeiro

Investigação do uso de imagens de sensor de sensoriamento remoto hiperespectral e com alta resolução espacial no monitoramento da condição de uso de pavimentos rodoviários / M.R. Resende. -- São Paulo, 2010.

130 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Transportes.

1.Sensoriamento remoto 2.Imagem hiperespectral 3.Pavimentos asfálticos 4.Classificação de imagem I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Transportes II.t.

Aos meus pais queridos, Janeaut (*In memorian*) e Maria Anita, pelo exemplo, pela moral, pelo amor e pela dedicação incondicional aos seus filhos.

Aos meus irmãos queridos: Marilene, Mariluce, Márcio, Marilda, Marise, Marília e Mariângela. Vocês foram muito mais do que irmãos: foram pais e referência de vida.

À minha esposa amada Saron, minha companheira eterna.

Aos meus filhos maravilhosos Pietra e Hector

AGRADECIMENTOS

Ao Prof. Dr. José Alberto Quintanilha pela atenção e serenidade na condução e orientação deste trabalho

Ao Departamento de Transporte da Escola Politécnica da USP pela oportunidade e o acolhimento desta pesquisa.

À Fundação Atech Tecnologias Críticas pela cessão das imagens.

Aos amigos do Laboratório de Geoprocessamento.

SUMÁRIO

1	Introdução.....	18
1.1	Descrição da Pesquisa	20
1.2	Justificativa.....	21
1.3	Objetivos.....	21
2	Fundamentação Teórica.....	23
2.1	Conceitos em sensoriamento remoto.....	23
2.1.1	O modelo de sensoriamento remoto	25
2.1.1.1	Fonte de energia	25
2.1.1.2	Propagação da energia pela atmosfera	29
2.1.1.3	Interação da energia com as características da superfície.....	31
2.1.1.4	Sensores e Plataformas.....	32
2.1.1.5	Processamento e análise.....	33
2.1.1.6	Aplicações	34
2.2	Análise de Imagens Baseada em Objetos - OBIA.....	35
2.3	Classificação de imagens.....	37
2.3.1	Classificação <i>Spectral Angle Mapper</i> (SAM)	39
2.3.2	Segmentação.....	40
2.3.3	Resolução em imagens	41
2.4	Lógica <i>fuzzy</i> (Nebulosa)	42
2.5	<i>Fuzzy</i> e processamento de imagem.....	44
2.6	Sensor Hiperespectral	45
2.7	Sistema de Monitoramento Aéreo de Baixo Custo (SMABC).....	46
2.8	Pavimentos asfaltados	46
2.8.1	Classificação e definição dos defeitos do pavimento	48
2.8.1.1	Fenda (F)	48
2.8.1.2	Afundamento (A)	49
2.8.1.3	Ondulação ou Corrugação (O)	50
2.8.1.4	Escorregamento (E).....	50
2.8.1.5	Exsudação (EX)	50
2.8.1.6	Desgaste (D).....	50
2.8.1.7	Panela ou buraco (P)	50
2.8.1.8	Remendo (R)	51

2.8.2	Avaliação objetiva de superfície pela determinação do IGG	52
2.8.3	Levantamento Visual Contínuo (LVC)	54
3	Recursos Empregados na Pesquisa.....	58
3.1	Área de Estudo	58
3.2	Imagens do Sensor CASI-1500	59
3.3	Programa ENVI.....	63
3.4	Programa eCognition.....	63
4	Metodologia.....	64
4.1	Processo Detectar Asfalto.....	65
4.2	Classificação dos Defeitos do Asfalto.....	69
5	Resultados.....	71
5.1	Áreas de Interesse (AOI)	71
5.2	Avaliação da qualidade das imagens.....	74
5.3	Biblioteca espectral	78
5.4	Pesquisa de Campo.....	81
5.5	Resultados do Processo Detectar Asfalto	86
5.5.1	Avaliação dos filtros espaciais	86
5.5.2	Resultados após a classificação por objetos	89
5.6	Resultados do Processo de Classificação dos Defeitos do Asfalto	93
5.6.1	Processamento dos Remendos.....	94
5.6.2	Processamento das Trincas Longas	99
5.6.3	Processamento dos Buracos/Panelas	105
5.6.4	Análise com as Componentes Principais.....	105
5.6.5	Geração dos Índices de Defeitos do Asfalto.....	109
6	Discussão.....	111
6.1.1	Sobre a primeira etapa da metodologia: Detectar Asfalto.....	113
6.1.2	Sobre a segunda etapa da metodologia: Classificação dos Defeitos do Asfalto ...	117
6.2	Sugestões para trabalhos futuros	120
7	Conclusão	121
	REFERÊNCIAS	125

LISTA DE ILUSTRAÇÕES

Figura 1 - Primeira imagem aérea preservada, Boston, Massachussets (SHORT, 2009).....	24
Figura 2 - Modelo do sensoriamento remoto. Adaptado de CCRS.....	25
Figura 3 - Onda eletromagnética.....	26
Figura 4 - Espectro eletromagnético. Adaptado de CCRS.	27
Figura 5 - Espectro eletromagnético da faixa infravermelho. Adaptado de CCRS.....	27
Figura 6 - Distribuição espectral da energia radiada de Corpos Negros. Adaptado de Lillesand, Kiefer e Chipman (2007).	28
Figura 7 - Janelas atmosféricas. Adaptado de Short (2009).	30
Figura 8 - Janelas atmosféricas vezes a energia irradiada. Adaptado de Short (2009).	30
Figura 9 - Curvas espectrais extraídas a partir de uma imagem multiespectral (24 bandas). Sensor CASI 1500. Mogi Guaçu, São Paulo, Brasil (ATECH, 2007).....	31
Figura 10 - (a) Imagem original, (b) imagem classificada usando técnica <i>pixel a pixel</i> e (c) imagem classificada usando a técnica baseada em objeto (DEFINIENS, 2004).....	35
Figura 11 - Imagem espectral. Adaptado de Short (2009).....	38
Figura 12 - (a) Imagem original (ATECH, 2007) e (b) imagem classificada <i>pixel a pixel</i> (RESENDE et al., 2008).....	39
Figura 13 - Conceito do SAM. Adaptado de Boardman (1993).	40
Figura 14 - Imagem segmentada	41
Figura 15 - Lógica tradicional.....	43
Figura 16 - Número <i>fuzzy</i>	43
Figura 17 - Função de pertinência trapezoidal	43
Figura 18 - Funções de pertinência S, Pi e Z.....	43
Figura 19 - Exemplos de função de pertinência no software eCognition (DEFINIENS, 2004).....	44
Figura 20 - Base de regras <i>fuzzy</i> (DEFINIENS, 2004).....	45
Figura 21 – Área de Estudo, Sorocaba, São Paulo – SP.	59
Figura 22 – Imagem 01 com 24 bandas espectrais e 50 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).	61

Figura 23 – Imagem 02 com 24 bandas espectrais e 50 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).	61
Figura 24 – Imagem 03 com 8 bandas espectrais e 25 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).	62
Figura 25 – Imagem 04 com 8 bandas espectrais e 25 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).	62
Figura 26 - Visão geral da metodologia para monitoramento da condição dos pavimentos asfaltados a partir de imagens hiperespectrais e de alta resolução espacial	64
Figura 27 - Metodologia para detecção e separação do asfalto em imagens hiperespectrais	66
Figura 28 - Imagem com informação de asfalto resultado do algoritmo de classificação supervisionada SAM.....	67
Figura 29 – Classes utilizadas na classificação por objetos para remoção de áreas classificadas erroneamente como asfalto.....	68
Figura 30 - Imagem com informação de asfalto resultado do algoritmo de classificação baseada em objetos	68
Figura 31 - Metodologia para classificação dos defeitos do asfalto	70
Figura 32 – Área de Interesse – 01, resolução espacial 25 cm e 8 bandas espectrais, amostra da imagem 03 (Figura 24) (ATECH, 2010).	72
Figura 33 – Área de Interesse – 02, resolução espacial 25 cm e 8 bandas espectrais, amostra da imagem 03 (Figura 24) (ATECH, 2010).	72
Figura 34 – Área de Interesse – 03, resolução espacial 25 cm e 8 bandas espectrais, amostra da imagem 03 (Figura 24) (ATECH, 2010).	73
Figura 35 – Área de Interesse – 06, resolução espacial 50 cm e 24 bandas espectrais, amostra da imagem 02 (Figura 23) (ATECH, 2010).	73
Figura 36 – Área de Interesse – 08, resolução espacial 50 cm e 24 bandas espectrais, amostra da imagem 02 (Figura 23) (ATECH, 2010).	73
Figura 37 – Curva espectral padrão asfalto (CLARK et al., 2003).	75
Figura 38 – Detalhe da absorção de energia em 940nm. Curva de transmitância da atmosfera padrão. Adaptado de Clark (1999).	76
Figura 39 – (a) Imagem original e (b) PC8 – oitava componente do resultado da Análise de Componentes Principais	76
Figura 40 – Exemplo de linha atenuada encontrada nas imagens.	77

Figura 41 – Exemplo de uma região saturada.....	77
Figura 42 – Curvas espectrais de rodovias da biblioteca NCRST (HEROLD et al.)..	78
Figura 43 – Amostras de asfalto para composição da biblioteca espectral. (a) asfalto claro sem tráfego, (b) e (c) asfalto claro alça de acesso, (d) asfalto claro rodovia, (e) faixa rodagem externa rodovia, (f) faixa de rodagem interna rodovia, (g) remendos, (h) asfalto recapeado.	80
Figura 44 – Curvas espectrais das amostras de asfaltos da Figura 43.....	80
Figura 45 – (a) AOI-01 e pontos de coleta das imagens; (b), (c) e (d) imagens da pesquisa de campo.	81
Figura 46 – (a) AOI-02 e pontos de coleta das imagens; (b), (c) e (d) imagens da pesquisa de campo.	82
Figura 47 – (a) AOI-02 e pontos de coleta das imagens; (b), (c) e (d) imagens da pesquisa de campo.	83
Figura 48 – (a) AOI-04 e pontos de coleta das imagens; (b), (c), (d), (e) e (f) imagens da pesquisa de campo.....	84
Figura 49 – (a) AOI-02 e pontos de coleta das imagens; (b), (c), (d), (e) e (f) imagens da pesquisa de campo.....	85
Figura 50 – Experimento Árvore de decisão – Filtros espaciais.....	87
Figura 51 – Tela do programa eCognition com os parâmetros de segmentação da imagens para classificação dos remendos.....	94
Figura 52 – (a) Ilustração do conceito de Índice de Borda. (b) Ilustração do conceito do Índice de Forma utilizados pelo software eCognition.....	95
Figura 53 – (a) Descrição da classe Remendo em termos das funções de pertinência. (b) Histograma dos atributos utilizados nas funções de pertinência da classe Remendo.	96
Figura 54 – Recorte da AOI-01 ilustrando os remendos no asfalto.	98
Figura 55 – Em destaque (vermelho) os remendos identificados na classificação baseada em objetos	98
Figura 56 – (a) Descrição da classe TrincaLonga em termos das funções de pertinência. (b) Histograma dos atributos utilizados nas funções de pertinência da classe TrincaLonga.	102
Figura 57 – Em destaque (vermelho) as trincas identificadas na classificação baseada em objetos. Segmentação escala 20, forma 0,7 e compacidade 0,9. Recorte da AOI-03.....	103

Figura 58 – Em destaque (vermelho) as trincas identificadas na classificação baseada em objetos. Segmentação escala 20, forma 0,7 e compacidade 0,9. Recorte da AOI-04.....	103
Figura 59 – Recorte da imagem da AOI-01 contendo remendos. (a) Primeira componente principal. (b) Segunda componente principal. (c) Terceira componente principal. (d) Quarta componente principal.	106
Figura 60 – Recorte da imagem da AOI-04 contendo “trincas longas” seladas. (a) Primeira componente principal. (b) Segunda componente principal. (c) Terceira componente principal. (d) Quarta componente principal.....	107
Figura 61 – Recorte da segmentação da AOI-03 sobre as imagens das componentes principais 1, 2, 3 e 4. (a) Segmentação com escala 20, forma 0,7 e compacidade 0,9. (b) Segmentação com escala 50, forma 0,1 e compacidade 0,9.....	108
Figura 62 – (a) Imagem espectral de um trecho com ruído eletrônico. (b) Resultado da classificação SAM para área com ruído eletrônico.	113
Figura 63 – (a) Resultado da classificação SAM para área com ruído eletrônico. (b) Resultado da classificação após a aplicação dos filtros.	115
Figura 64 – Oitava componente principal da AOI-01 identificando o ruído eletrônico na parte inferior direita da imagem.	116

LISTA DE TABELAS

Tabela 1 - Extensão das rodovias brasileiras pavimentadas.	18
Tabela 2 - Classificação do pavimento extensão total.	19
Tabela 3 - Quadro resumo dos defeitos dos pavimentos – Codificação e Classificação.	51
Tabela 4 - Quadro resumo dos defeitos dos pavimentos – Codificação e Classificação (Cont.).	52
Tabela 5 - Valor do fator de ponderação dos tipos de ocorrência.....	54
Tabela 6 - Conceitos de degradação do pavimento em função do IGG.	54
Tabela 7 – Frequência de defeitos para o LVC.	55
Tabela 8 – Conceitos do ICPF.	56
Tabela 9 – Pesos para cálculo IGGE.	57
Tabela 10 – Índice do Estado da Superfície do pavimento.	57
Tabela 11 – Detalhamento das bandas espectrais das imagens do conjunto de dados.	60
Tabela 12 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para os nós da árvore de decisão da Figura 50.....	88
Tabela 13 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-01.....	89
Tabela 14 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-02.....	89
Tabela 15 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-03.....	90
Tabela 16 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-06.....	90
Tabela 17 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-08.....	90
Tabela 18 – Avaliação da aplicação dos filtros espaciais e da classificação por objetos às AOI.....	91
Tabela 19 – Sequência de passos e seus resultados para o processo Detectar Asfalto.....	91

Tabela 20 – Resultado da classificação baseada em objetos para identificação de remendos.	97
Tabela 21 – Estudo dos parâmetros de segmentação para a classe trincas longas.	100
Tabela 22 – Estudo dos parâmetros de segmentação para a classe trincas longas (Cont.).....	101
Tabela 23 – Resultado da classificação baseada em objetos das AOI para identificação de “trincas” longas.....	104
Tabela 24 – Resultado da classificação baseada em objetos das AOI transformadas em componentes principais para identificação de remendos.	108
Tabela 25 – Resultado da classificação baseada em objetos das AOI transformadas em componentes principais para identificação de “trincas” longas.....	109
Tabela 26 – Cálculo do IGI’ e do IGG’ a partir das imagens.	110
Tabela 27 – Cálculo do IGGE’ a partir das imagens.....	110
Tabela 28 – Comparação da exatidão geral das áreas de interesse antes e depois da aplicação dos filtros de Clump, Sieve e Média.....	116

LISTA DE SIGLAS

AETT	Anuário Estatístico dos Transportes Terrestres
AFP	Afundamento Plástico Local
ALC	Afundamento de Consolidação Local
ANTT	Agência Nacional de Transportes Terrestres
ATECH	Fundação Aplicações de Tecnologias Críticas
ATC	Afundamento de Consolidação da Trilha
ATP	Afundamento Plástico da Trilha
AVIRIS	Airborne Visible/IR Imaging Spectrometer
CASI	Compact Airborne Spectrographic Imager
CBERS	China-Brazil Earth Resources Satellite
CCD	Charge-Coupled Device
CCRS	Canada Centre for Remote Sensing
CNT	Confederação Nacional de Transporte
D	Desgaste
DNER	Departamento Nacional de Estradas e Rodagem
DNIT	Departamento Nacional de Infra-Estrutura de Transportes
E	Escorregamento
ETM+	Enhanced Thematic Mapper Plus
EX	Exsudação
FC-1	Fenda Classe 1
FC-2	Fenda Classe 2
FC-3	Fenda Classe 3
FINEP	Financiadora de Estudos e Projetos
FOV	Field of View
FP	Fator de Ponderação
GIS	Geographic Information System
GIScience	Geographic Information Science
GOES	Geostationary Operational Environmental Satellites
IFOV	Instantaneous Field Of View
IGI	Índice de Gravidade Individual
IGG	índice de Gravidade Global

IR	Infrared
IRMSS	Infrared Multispectral Scanner System
J	Trinca interligada “Jacaré” sem erosão
JE	Trinca interligada “Jacaré” com Erosão
LIDAR	Light Detection and Ranging
MSS	Multispectral Scanner System
NCRST	National Center for Remote Sensing in Transportation
ND	Número Digital
O	Ondulação/Corrugação
OBIA	Object-Based Image Analysis
P	Panela ou buraco
PCA	Análise de Componente Principal
RS	Remendo Superficial
RP	Remendo Profundo
SAM	Spectral Angle Mapper
SAR	Radar de Abertura Sintética
SIVAM	Sistema de Vigilância da Amazônia
SMABC	Sistema de Monitoramento Aéreo de Baixo Custo
SRTM	Shuttle Radar Topography Mission
TB	Trinca interligada em Bloco sem erosão
TBE	Trinca interligada em Bloco com Erosão
TLC	Trinca Longitudinal Curta
TLL	Trinca Longitudinal Longa
TRR	Trinca Retração Revestimento
TTC	Trinca Transversal Curta
TTL	Trinca Transversal Longa
UAV	Unmanned Aerial Vehicles
UV	Ultravioleta
VANT	Veículos Aéreos Não Tripulados
VHSR	Very High Spatial Resolution
VNIR	Visible Near Infrared
WFI	Wide Field Imager

RESUMO

Segundo a Agência Nacional de Transportes Terrestres (ANTT) em seu Anuário Estatístico dos Transportes Terrestres – AETT (2008), o Brasil em todo o seu território possui 211.678 quilômetros de rodovias pavimentadas. “O valor de serventia do pavimento diminui com o passar do tempo por dois fatores principais: o tráfego e as intempéries” (BERNUCCI et al., 2008). Monitorar a condição de uso de toda a extensão das rodovias brasileiras é tarefa dispendiosa e demorada. A investigação de novas técnicas que permitam o levantamento da condição dos pavimentos de forma ágil e automática é parte da pesquisa deste trabalho. Nos últimos anos, um número crescente de imagens de alta resolução espacial tem surgido no mercado mundial com o aparecimento dos novos satélites e sensores aeroembarcados de sensoriamento remoto. Da mesma forma, imagens multiespectrais e até mesmo hiperespectrais estão sendo disponibilizadas comercialmente e para pesquisa científica. Neste trabalho são utilizadas imagens hiperespectrais de sensor digital aeroembarcado. Uma metodologia para identificação automática dos pavimentos asfaltados e classificação das principais ocorrências dos defeitos do asfalto foi desenvolvida. A primeira etapa da metodologia é a identificação do asfalto na imagem, utilizando uma classificação híbrida baseada inicialmente em *pixel* e depois refinada por objetos foi possível a extração da informação de asfalto das imagens disponíveis. A segunda etapa da metodologia é a identificação e classificação das ocorrências dos principais defeitos nos pavimentos flexíveis que são observáveis nas imagens de alta resolução espacial. Esta etapa faz uso intensivo das novas técnicas de classificação de imagens baseadas em objetos. O resultado final é a geração de índices da condição do pavimento, a partir das imagens, que possam ser comparados com os indicadores da qualidade da superfície do pavimento já normatizados pelos órgãos competentes no país.

Palavras-chave: Sensoriamento remoto. Imagem hiperespectral. Pavimentos asfálticos. Classificação de imagem.

ABSTRACT

According to Statistical Survey of Land Transportation – AETT (2008) of National Agency of Land Transportation (ANTT), Brazil has in its territory 211,678 kilometers of paved roads. “The pavement Present Serviceability Ratio (PSR) value decreases over time by two main factors: traffic and weather” (BERNUCCI et al., 2008). Monitor the condition of use of all Brazilian roads is expensive and time consuming task. The investigation of new techniques that allow a quick and automatic survey of pavement condition is part of this research. In recent years, an increasing number of images with high spatial resolution has emerged on the world market with the advent of new remote sensing satellites and airborne sensors. Similarly, multispectral and even hyperspectral imagery are become available commercially and for scientific research nowadays. Hyperspectral images from digital airborne sensor have been used in this work. A new methodology for automatic identification of asphalted pavement and also for classification of the main defects of the asphalt has been developed. The first step of the methodology is the identification of the asphalt in the image, using hybrid classification based on pixel initially and after improved by objects. Using this approach was feasible to extract asphalt information from the available images. The second step of the methodology is the identification and classification of the main defects of flexible pavement surface that are observable in high spatial resolution imagery. This step makes intensive use of new techniques for classification of images based on objects. The goal, is the generation of pavement surface condition index from the images that can be compared with quality index of pavement surface that are already regulated by the regulatory agency in the country.

Keywords: Remote Sensing. Hyperspectral image. Asphalt pavement. Image classification.

1 Introdução

Segundo a Agência Nacional de Transportes Terrestres (ANTT) em seu Anuário Estatístico dos Transportes Terrestres – AETT (2008), o Brasil em todo o seu território possui 211.678 km de rodovias pavimentadas, sendo 61.304 km de rodovias federais, 17.056 km de rodovias estaduais coincidentes, 106.548 km de rodovias estaduais e 26.770 km de rodovias municipais.

Tabela 1 - Extensão das rodovias brasileiras pavimentadas.

REGIÃO	2007			
	FED	ESTC	EST	MUN
NORTE	7.172	174	8.860	1.048
NORDESTE	18.967	3.685	31.909	1.557
SUDESTE	13.877	7.817	32.759	15.411
SUL	10.796	3.687	17.660	7.967
CENTRO-OESTE	10.493	1.693	15.360	788
TOTAL	61.304	17.056	106.548	26.770

Fonte: Adaptado de AETT (2008)

O transporte é fundamental na integração entre as áreas de produção e consumo, e, também, das pessoas. As rodovias apresentam-se como a infraestrutura de primeiro grau de acesso a essa integração. É por meio delas que acontece a coleta de cargas nas áreas agrícolas, a acessibilidade aos terminais de transferência modal - como portos, ferrovias e aeroportos -, o acesso direto a fábricas e centros de distribuição de produtos. São as rodovias que garantem a liberdade e a democracia de acesso da população a metrópoles, cidades e povoados, possibilitando relações comerciais, financeiras, de lazer e turismo entre as diversas localidades. O setor rodoviário é responsável por mais de 90% do transporte de passageiros e 61% do transporte de cargas. Os custos operacionais dos transportadores estão diretamente ligados aos gastos com combustíveis, pneumáticos e demais itens mecânicos. Aos custos que envolvem todos os usuários de rodovias podem-se acrescentar os atrasos de viagens, os congestionamentos e os acidentes de trânsito. Em ambos os casos, percebe-se consequências diretas da qualidade e da capacidade da via sobre os custos de movimentação (Pesquisa rodoviária CNT, 2007).

Segundo a pesquisa rodoviária CNT (2009), “o levantamento realizado pela pesquisa em 89.552 km da malha rodoviária do país, em 43,4% (38.870 km) a condição da superfície de rolamento é, predominantemente, totalmente perfeita. Por sua vez, em 33,1 % o pavimento apresenta sinais de desgaste e, em 23,5 % predominam defeitos, principalmente trinca em malha e/ou remendos (17,8%) e

afundamentos, ondulações e buracos (4,6%). A situação crítica, pavimento totalmente destruído, é predominante em 1,1%, ou seja, 960 km”.

A Tabela 2 apresenta o resultado da pesquisa CNT (2009) para a avaliação qualitativa geral dos pavimentos.

Tabela 2 - Classificação do pavimento extensão total.

Pavimento	Extensão Total	
	km	%
Ótimo	34.459	38,5
Bom	6.494	7,3
Regular	36.006	40,1
Ruim	9.097	10,2
Péssimo	3.496	3,9
Total	89.552	100

Fonte: CNT, 2009.

“O valor de serventia do pavimento diminui com o passar do tempo por dois fatores principais: o tráfego e as intempéries” (BERNUCCI et al., 2008).

Segundo Herold et al. (2008), o custo das inspeções extensivas é alto e muitos municípios, quando fazem, limitam suas pesquisas às principais rodovias, enquanto as rodovias secundárias são relegadas ao esquecimento ou a pouquíssimas inspeções. Com esse propósito, um número grande de tecnologias vem sendo aplicadas ao monitoramento das condições das estradas. O avanço recente na tecnologia de sensoriamento remoto tem demonstrado capacidade em detectar propriedades físicas e químicas dos materiais.

As imagens de sensoriamento remoto, dia após dia, têm se tornado ricas em informações para o usuário, principalmente no que diz respeito a resolução espacial, espectral, temporal, textura e precisão. Junto com a melhoria na qualidade das imagens de sensoriamento remoto surge a dificuldade de tratamento de um volume substancial de dados para obtenção de informação de interesse. As técnicas utilizadas para classificação de imagens até recentemente baseadas em *pixel* já não atendem as demandas originadas com o surgimento das novas imagens do sensoriamento.

“Procedimentos baseados em *pixel* são exclusivamente estatísticos e não utilizam a dimensão espacial da informação. Com a alta resolução das imagens onde um *pixel* não é mais automaticamente maior ou igual aos objetos pesquisados,

além de métodos de classificação, novas concepções metodologias são procuradas” (BLASCHKE; KUX, 2005).

“Surge então uma nova visão para o processamento de imagens, o processamento de informação com base no objeto. Ao invés de classificar os *pixels* individualmente quanto as suas características espectrais, os novos procedimentos consideram a delimitação de objetos homogêneos como a base para o processamento posterior” (BLASCHKE; KUX, 2005).

Neste contexto, os classificadores baseados em objetos utilizam-se de técnicas como a lógica *fuzzy* para mapear o conhecimento do especialista e realizar os métodos de classificação.

1.1 Descrição da Pesquisa

A pesquisa tem com base a investigação da utilização de imagens digitais de alta resolução espacial e espectral no monitoramento da condição de uso dos pavimentos asfaltados. Para tanto, foi criada uma metodologia de processamento e análise das imagens com o objetivo de extrair índices de qualidade dos pavimentos diretamente das imagens coletadas. As principais etapas da pesquisa podem ser resumidas em:

1. Estudo das novas técnicas de análise de imagens baseadas em objetos;
2. Levantamento das imagens e área de interesse;
3. Estudo dos defeitos dos pavimentos;
4. Elaboração de uma metodologia para extração das informações de asfalto das imagens;
5. Elaboração de uma base de conhecimento capaz de identificar e classificar as ocorrências dos principais defeitos nos pavimentos flexíveis que são observáveis nas imagens de alta resolução espacial.

Para tanto, no capítulo 2 é apresentada a revisão do conceito de sensoriamento remoto, de análise baseada em objetos, dos métodos de classificação, dos sensores e dos principais defeitos dos pavimentos flexíveis. No

capítulo 3 são apresentados os recursos utilizados na pesquisa. No capítulo 4 é descrita a metodologia de processamento e análise das imagens. No capítulo 5 são apresentados os resultados. No capítulo 6 é apresentada a discussão dos resultados alcançados. No capítulo 7 a conclusão e por fim as referências bibliográficas.

1.2 Justificativa

A evolução recente na análise de imagens de sensoriamento remoto empurrando a classificação do nível do *pixel* para a fronteira do objeto vem causando mudanças e também interesse na comunidade científica brasileira e mundial. Da mesma forma, a evolução das tecnologias e equipamentos utilizados na aquisição de imagens, sejam elas aerotransportadas ou orbitais, proporcionam uma melhoria constante da qualidade das imagens disponíveis no mercado. Não obstante, novos sistemas de coleta têm propiciado a queda no custo de aquisição de imagens para sensoriamento remoto. A grande extensão das rodovias pavimentadas brasileiras e a importância delas como infra-estrutura básica para a economia do país, bem como a necessidade de um monitoramento contínuo da qualidade dos pavimentos são justificativas para o desenvolvimento desta pesquisa. A utilização das novas técnicas de análise de imagens em conjunto com novos sensores digitais de alta resolução espacial e espectral aplicados ao monitoramento da condição de uso de pavimentos rodoviários sustenta a proposição deste trabalho.

1.3 Objetivos

A pesquisa tem como objetivo principal a investigação da utilização de imagens digitais de alta resolução espacial e espectral no monitoramento da condição de uso dos pavimentos asfaltados. Pode-se ressaltar ainda como objetivos da pesquisa:

1. Elaborar uma metodologia de extração automática das vias asfaltadas a partir de imagens hiperespectrais, utilizando-se de uma classificação híbrida, *pixel a pixel* e baseada em objetos;

2. Investigar quais defeitos dos pavimentos flexíveis são detectáveis pelas imagens propostas na pesquisa;
3. Elaborar uma base de conhecimento capaz de identificar e classificar as ocorrências dos principais defeitos nos pavimentos flexíveis, observáveis nas imagens de alta resolução espacial, fazendo uso intensivo das técnicas de classificação baseadas em objetos;
4. Gerar índices da qualidade do asfalto, a partir das imagens, e que possam ser comparados com índices já normatizados pelos órgãos competentes do país.

2 Fundamentação Teórica

2.1 Conceitos em sensoriamento remoto

Sensoriamento remoto possui várias definições que variam ligeiramente de autor para autor. O termo sensoriamento remoto é um termo relativamente recente. Segundo o *Canada Centre for Remote Sensing – CCRS*, a Sra. Evelyn Pruitt do *United States Office of Naval Research* criou o termo sensoriamento remoto em 1958 para englobar fotografia aérea, imagem baseada em satélite e outras formas de coletar dados remotamente. A partir de então, o termo tem sido empregado amplamente e sendo definido e redefinido por alguns autores.

Segundo Fisher et al. (1976), “sensoriamento remoto é, basicamente, a arte ou a ciência de dizer alguma coisa sobre um objeto sem tocá-lo”.

Segundo Lillesand, Kiefer e Chipman (2007), “sensoriamento remoto é a ciência e a arte de obter informações sobre objetos, áreas ou fenômeno através da análise de dados obtidos por um dispositivo que não está em contato direto com o objeto, área ou fenômeno sob investigação”.

Segundo o CCRS, “sensoriamento remoto é a ciência (e, em certa medida, a arte) de aquisição de informações sobre a superfície da Terra sem realmente estar em contato com ela. Isto é feito por sensores e gravação da energia refletida ou emitida, processamento, análise e aplicação dessa informação”. Na definição do CCRS, sensoriamento remoto se restringe somente ao monitoramento da superfície da Terra, no entanto, a mesma tecnologia é utilizada na astronomia para a observação e estudo de outros planetas.

De forma sucinta, o ponto comum entre as definições de sensoriamento remoto está em adquirir informações sem contato físico com o objeto ou fenômeno de interesse.

A visão humana é um impressionante sistema de sensoriamento remoto. Nossos olhos detectam a luz visível refletida do nosso entorno que o cérebro percebe como uma imagem. Nós mentalmente interpretamos as cores, texturas, formas e tamanho das características para deduzir

informações sobre as mesmas, tais como a sua identidade (ou seja, quem ou o que eles são), a sua condição, sua velocidade e direção do movimento e outras qualidades. Embora, o nosso sistema de visão seja impressionante, tem as suas limitações para o mapeamento e inventário dos recursos da Terra. Nossa capacidade de armazenar e recuperar as imagens é inexata. Não há nenhuma maneira de reproduzir fielmente o que vemos, e não podemos obter informações de ondas eletromagnéticas que o olho não é sensível. A tecnologia de sensoriamento remoto oferece uma série de importantes vantagens em relação a visão subjetiva do ser humano. Fornece uma visão sinóptica que permite ver de uma só vez as diversas partes. Imagens podem ser obtidas rapidamente e repetidamente sobre grandes áreas. Por esta razão, é hoje, parte integrante da maioria dos recursos de mapeamento e procedimentos de inventário (CCRS).

“Os dados coletados remotamente podem ser de várias formas, incluindo variação na distribuição de forças, distribuição de ondas acústicas ou distribuição de energia eletromagnética” (LILLESAND; KIEFER; CHIPMAN, 2007).

Como o trabalho desenvolvido nesta dissertação faz uso, principalmente, de imagens para o monitoramento da condição de uso de pavimentos rodoviários, será dado enfoque nos sensores de energia eletromagnética para formação de imagens que atualmente tem sido operado principalmente por aeronaves e satélites.

Segundo Short (2009), a primeira imagem aérea conhecida foi obtida em 1858, Paris, França. A fotografia foi tirada de um balão por um fotógrafo e balonista francês, Gaspard-Félix Tournachon, também conhecido como Felix Nadar.

Figura 1 - Primeira imagem aérea preservada, Boston, Massachussets (SHORT, 2009).

Durante a guerra civil Americana de 1860, balonistas tiraram fotos da superfície terrestre utilizando as recentes câmeras fotográficas criadas naquela época. Esses balões eram utilizados para reconhecimento de áreas de interesse. A foto da Figura 1 foi tirada de um balão ancorado próximo da cidade de Boston, Massachusetts em 1860 e é a primeira fotografia aérea do planeta que foi preservada até os dias atuais (SHORT, 2009).

2.1.1 O modelo de sensoriamento remoto

A Figura 2 ilustra o processo e os elementos envolvidos no modelo conceitual do sensoriamento remoto. Os dois processos básicos envolvidos são os de aquisição de dados e análise de dados.

Figura 2 - Modelo do sensoriamento remoto. Adaptado de CCRS.

Os elementos do processo de aquisição e análise de dados são: a fonte de energia (A), propagação da energia pela atmosfera (B), interação da energia com as características da superfície (C), retransmissão da energia pela atmosfera (B'), sensor (D), transmissão, recepção e gravação (E), interpretação e análise (F), e finalmente a aplicação (G).

2.1.1.1 Fonte de energia

O primeiro requisito do Sensoriamento Remoto é ter uma fonte de energia para iluminar o alvo ou superfície de interesse (Exceto os casos de sensoriamento remoto em que é feita a observação da energia emitida pelo alvo, neste caso, o

próprio alvo é a fonte de energia). No modelo, o sol é a fonte natural de energia para o sensoriamento remoto.

“A luz visível é somente uma de muitas formas de energia. Ondas de rádio, calor, raios ultravioletas e raios X são outras formas conhecidas” (LILLESAND; KIEFER; CHIPMAN, 2007).

Essa energia está na forma de radiação eletromagnética. Radiação eletromagnética consiste de um campo elétrico que varia em amplitude perpendicularmente a direção na qual a radiação está propagando, consiste também de um campo magnético formando um ângulo reto com o campo elétrico, conforme Figura 3.

Figura 3 - Onda eletromagnética

Duas características da radiação eletromagnética são importantes para o sensoriamento remoto: comprimento de onda (λ) e frequência (ν). Estas duas características se relacionam pela seguinte fórmula:

$$c = \lambda \cdot \nu \quad (1)$$

onde:

c = velocidade da luz (3×10^8 m/s);

λ = comprimento de onda (m);

ν = frequência (Hz).

Entender as características da radiação eletromagnética em termos do comprimento de onda e frequência é crucial para entender as informações que serão extraídas dos dados de sensoriamento remoto.

O espectro eletromagnético, a variação do comprimento de onda e da frequência são apresentados na Figura 4.

Figura 4 - Espectro eletromagnético. Adaptado de CCRS.

“Embora, por conveniência, nomes sejam atribuídos às regiões do espectro eletromagnético, não há uma linha divisória clara entre uma região do espectro e a outra” (LILLESAND; KIEFER; CHIPMAN, 2007).

Figura 5 - Espectro eletromagnético da faixa infravermelho. Adaptado de CCRS.

“Do ponto de vista do sensoriamento remoto, as faixas mais importantes do espectro eletromagnético são: ultravioleta, visível, infravermelho e microondas”

(LILLESAND; KIEFER; CHIPMAN, 2007). Estas faixas são ainda divididas internamente, conforme o interesse da pesquisa e do sensoriamento remoto. Da mesma forma que o espectro visível se divide em Azul (400nm a 500nm), Verde (500nm a 600nm) e Vermelho (600nm a 700nm), as faixas do infravermelho e microondas também são divididas.

O infravermelho é dividido em infravermelho próximo, médio e distante. Entretanto, o infravermelho distante possui uma característica particular. Nesta faixa do espectro, a energia não é refletida de uma fonte, mas sim emitida pelos objetos ou alvos em observação, é conhecida como termal.

“A energia emitida dos objetos varia proporcionalmente em função da temperatura absoluta dos materiais numa relação exponencial T^4 . Essa Lei (Lei de Stefan-Boltzmann) é expressa para fonte de energia que se comporta como um Corpo Negro. Um Corpo Negro é um radiador ideal que absorve e emite totalmente a energia incidente sobre ele” (LILLESAND; KIEFER; CHIPMAN, 2007).

“Da mesma forma que a energia emitida de um objeto varia em função da temperatura, a distribuição espectral desta energia varia também” (LILLESAND; KIEFER; CHIPMAN, 2007). A Figura 6 mostra as curvas de distribuição de energia para Corpos Negros.

Figura 6 - Distribuição espectral da energia radiada de Corpos Negros. Adaptado de Lillesand, Kiefer e Chipman (2007).

Repare na Figura 6 que o pico máximo da curva espectral, na temperatura do sol, acontece exatamente na faixa do espectro visível. No caso da curva para a

temperatura da Terra, o pico acontece exatamente na faixa do infravermelho distante (Termal).

2.1.1.2 Propagação da energia pela atmosfera

A radiação eletromagnética sofre interferência ao atravessar a atmosfera Terrestre. Independente do tipo do sensor, sempre há uma distância entre a fonte emissora de energia e o sensor de detecção. O trajeto entre a fonte de energia e o sensor é dependente do tipo de sensoriamento remoto que é realizado. Um satélite que capta a radiação eletromagnética refletida da superfície Terrestre sofre duas vezes a influência da atmosfera terrestre. A primeira quando a energia do Sol atravessa a atmosfera até chegar a superfície terrestre e a segunda quando a energia refletida pela superfície atravessa a atmosfera até chegar de volta ao satélite que está em órbita ou até uma plataforma de imageamento. No caso de sensoriamento remoto por plataformas aéreas, a distância até o alvo, quando comparada com satélites, é significante menor, ou seja, quanto menor for a distância no trajeto da fonte de energia até o alvo de interesse e depois até o sensor, menor será a interferência da atmosfera na propagação da radiação eletromagnética.

A atmosfera pode ter profundos efeitos, além de outras coisas, na intensidade e na composição espectral da radiação disponível a qualquer sistema de sensoriamento. Os dois tipos de interferência são: espalhamento e absorção.

Há três tipos de espalhamento: Rayleigh, Mie e Não-Seletivo. O espalhamento de Rayleigh acontece quando o comprimento das moléculas ou outras partículas da atmosfera são muito menores do que o comprimento de onda da radiação emitida. Afeta principalmente os comprimentos de onda menores do que os maiores. O espalhamento de Mie acontece quando o comprimento das partículas da atmosfera é aproximadamente igual ao comprimento de onda da radiação emitida. Poeira, pólen, fumaça e vapor de água são causas comuns do espalhamento de Mie. Este tipo de espalhamento tende a influenciar mais os comprimentos de ondas maiores quando comparado com o espalhamento de Rayleigh. O último espalhamento, Não-Seletivo, acontece quando o diâmetro das partículas são muito maiores do que o comprimento de onda da radiação emitida. Gotas de água na atmosfera ou partículas grandes de poeira são causas deste espalhamento. Neste caso, o espalhamento acontece tanto no visível, como no infravermelho próximo e médio, por isso o termo Não-Seletivo em relação ao comprimento de onda.

O segundo tipo de interferência da atmosfera é a Absorção. Absorção é a perda de energia para os elementos constituintes da atmosfera. Os principais absorventes de radiação solar são: vapor de água, dióxido de carbono e ozônio. Estes gases absorvem a radiação em determinadas partes do espectro e produzem faixas onde a radiação consegue alcançar a

superfície terrestre. Estas faixas são chamadas de janelas atmosféricas (LILLESAND; KIEFER; CHIPMAN, 2007).

As janelas atmosféricas são limitantes ao emprego do sensoriamento remoto para certos comprimentos de onda. Antes da aplicação do sensoriamento remoto para identificação de determinada característica do objeto em pesquisa é necessário analisar o comportamento espectral do objeto frente às janelas atmosféricas. Muitas vezes, o comportamento espectral desejado do objeto não coincide com as janelas atmosféricas impedindo o desenvolvimento dos estudos, pesquisa e até mesmo do monitoramento. As janelas influenciam também na determinação do tipo de sensor que será utilizado no sensoriamento remoto.

Figura 7 - Janelas atmosféricas. Adaptado de Short (2009).

Figura 8 - Janelas atmosféricas vezes a energia irradiada. Adaptado de Short (2009).

2.1.1.3 Interação da energia com as características da superfície

A energia eletromagnética ao chegar à superfície terrestre interage com os objetos e elementos que a compõem. A interação da energia com a superfície terrestre depende principalmente do tipo, forma e da condição do material. Há três formas de interação da energia com a superfície terrestre: reflexão, absorção e transmissão. Tendo como base o princípio da conservação de energia, pode-se dizer que a energia incidente sobre um objeto é igual a soma das energias refletida, absorvida e transmitida. Matematicamente a expressão é a seguinte:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda)$$

onde:

E_I = energia incidente;

E_R = energia refletida;

E_A = energia absorvida;

E_T = energia transmitida.

Figura 9 - Curvas espectrais extraídas a partir de uma imagem multiespectral (24 bandas). Sensor CASI 1500. Mogi Guaçu, São Paulo, Brasil (ATECH, 2007).

Segundo Lillesand, Kiefer e Chipman (2007), “a proporção de energia refletida, absorvida e transmitida irá variar para diferentes características da Terra, dependendo do tipo e da condição do material. Essas diferenças permitem-nos distinguir diferentes características nas imagens. [...] há também uma dependência

do comprimento de onda. Para um mesmo tipo de característica, a proporção da energia refletida, absorvida e transmitida irá variar nos diferentes comprimentos de onda”.

Estes princípios são as bases dos algoritmos de tratamento e classificação de imagens que serão discutidos a seguir neste trabalho.

A partir deste princípio é possível construir um gráfico da refletância espectral de um objeto em função do comprimento de onda. Este gráfico é conhecido como sendo a curva espectral do objeto, ou também como a assinatura espectral do objeto. O conhecimento antecipado desta curva para os diferentes tipos de materiais observados no sensoriamento remoto permite reconhecer e analisar os objetos em uma imagem.

2.1.1.4 Sensores e Plataformas

Em relação aos sensores, estes podem ser passivos ou ativos. Sensor passivo é aquele que é capaz de captar a energia emitida por alguma outra fonte de radiação. Nesta categoria estão, principalmente, os sensores da faixa do espectro visível e infravermelho, o *Enhanced Thematic Mapper Plus* (ETM+) e o *Multispectral Scanner System* (MSS) ambos do satélite americano Landsat, o Imageador de Amplo Campo de Visada (*Wide Field Imager* - WFI) e o Imageador por Varredura de Média Resolução (IRMSS - *Infrared Multispectral Scanner System*) do satélite *China-Brazil Earth Resources Satellite* (CBERS) e o sensor *Compact Airborne Spectrographic Imager* (CASI) que é utilizado neste trabalho são alguns exemplos de sensores passivos.

O sensor ativo é aquele que emite a própria radiação para iluminar os alvos de interesse. Como exemplo de sensores ativos temos: radares de abertura sintética (SAR), radares meteorológicos, *Light Detection and Ranging* (LIDAR), dentre outros. A grande vantagem dos sensores ativos está no fato de não dependerem das fontes de energia naturais, o sol ou a energia emitida dos objetos (termal). Por essa razão, os sensores ativos podem ser utilizados durante o dia ou noite. No caso dos sensores SAR, é possível adquirir imagens de uma região independente das condições meteorológicas, ou seja, mesmo que a região esteja

encoberta pelas nuvens. Este tipo de sensor foi desenvolvido pelos militares para executar missões de reconhecimento noturno e/ou com céu nublado.

As plataformas de sensoriamento remoto podem ser terrestres (fixas ou móveis), aéreas ou espaciais. Uma torre de vigilância contra incêndios florestais com sensores óticos e termais é um exemplo de uma plataforma terrestre fixa. Já um veículo dotado de um perfilador laser e câmeras de imageamento para o monitoramento de pavimentos é um exemplo de plataforma terrestre móvel. Há um grande número de plataformas aéreas de sensoriamento, tais como: balões, aeronaves de pequeno, médio e grande porte, e também os veículos aéreos não tripulados (VANT ou a sigla em inglês para unmanned aerial vehicles - UAV). As plataformas espaciais podem ser orbitais ou geoestacionárias. Os satélites Landsat e CBERS são exemplos de plataformas orbitais, já os satélites meteorológicos METEOSAT e o Geostationary Operational Environmental Satellites (GOES) são exemplos de plataformas espaciais geoestacionárias.

2.1.1.5 Processamento e análise

Uma das principais etapas do sensoriamento remoto é a etapa de processamento e análise das imagens coletadas pelos sensores. Na etapa de processamento e análise é o momento em que o analista ou foto-intérprete irá extrair as informações das imagens coletadas. Por exemplo, numa campanha de levantamento para determinar a quantidade de área plantada de cana-de-açúcar, na etapa de processamento das imagens de satélites, o analista faz uso de ferramentas (softwares dedicados) para identificar e quantificar a área plantada da cana-de-açúcar. Desde o momento da captura das imagens até o processamento, os desafios são enormes para obter o resultado desejado de quantificar a área plantada, pois a área de interesse pode estar coberta por nuvens, o que não permitirá ao analista e ao software identificar a cultura de interesse, ou então, pode haver uma cultura semelhante plantada próxima que acaba dificultando o trabalho de classificação. Quando a área monitorada possui grandes dimensões, tais como: área de um estado ou grandes reservas, o trabalho de foto interpretação se torna extremamente oneroso e demorado, daí surgem técnicas e metodologias que

procuram minimizar o esforço necessário para processar e analisar as imagens de sensoriamento remoto.

Antes de iniciar a etapa de análise das imagens, em determinadas situações, se faz necessária uma etapa de pré-processamento ou adaptação das imagens. Nesta etapa de pré-processamento, as imagens são convertidas para formatos legíveis dos softwares especialistas. São feitas também correções radiométrica nas imagens, em função da característica específica do sensor utilizado (e.g., ruídos eletrônicos, erros de quantização quando da transformação do sinal analógico para digital, defeitos do sensor etc.). Correções geométricas são necessárias para que a imagem possa ser utilizada e que medidas possam ser retiradas das mesmas. A correção geométrica retira as possíveis distorções das imagens oriundas da posição do sensor em relação a terra no momento da captura da imagem (atitude do sensor). Em alguns casos, para sensores digitais modernos, esse processamento atribui os valores de coordenada geográfica para cada *pixel* da imagem automaticamente, desta forma, permitindo medir, comparar e sobrepor diferentes imagens de uma mesma região.

2.1.1.6 Aplicações

Atualmente, o sensoriamento remoto tem sido aplicado em diferentes áreas do conhecimento humano. Há aplicações na área ambiental, geologia, agricultura, florestal, meteorologia, hidrologia, uso e cobertura da terra (rural e urbana), oceanologia, transporte etc.

Especificamente, em relação à área de transportes, o sensoriamento remoto por meio de imagens tem crescido nas últimas décadas. As seguintes aplicações (a lista não é exaustiva) são encontradas na literatura.

- Uso de imagens de satélite como ferramenta de auxílio ao planejamento urbano.
- Detecção de arruamentos em áreas de ocupação urbana irregular com imagens do satélite.
- Determinação do índice de acessibilidade de uma região ou município através do uso de imagens de alta resolução espacial.

- Uso de imagens de alta resolução espectral e espacial na detecção de ruas asfaltadas.
- Monitoramento da condição da infra-estrutura rodoviária.
- Uso de imagens SAR para o monitoramento de embarcações.
- Uso de imagens UV (ultravioleta) e IR (infravermelhos) na localização e rastreamento de derramamentos de óleo nos oceanos ou em transporte fluvial.
- Uso de imagens SAR (interferometria) e LIDAR para levantamento topográfico e planejamento da malha viária.
- Uso de imagens hiperespectrais na detecção do envelhecimento do asfalto.
- Previsão da demanda de tráfego a partir da detecção de mudanças em áreas ocupadas por meio de imagens.

2.2 Análise de Imagens Baseada em Objetos - OBIA

“Análise de imagens implica lidar com a semântica da imagem. Na maioria dos casos a informação semântica importante para entender uma imagem não está representada em pixels individuais, mas em objetos de imagem significativos e suas relações mútuas” (BAATZ; SCHAPE, 2000).

Figura 10 - (a) Imagem original, (b) imagem classificada usando técnica *pixel a pixel* e (c) imagem classificada usando a técnica baseada em objeto (DEFINIENS, 2004).

A técnica de classificação de imagens *pixel a pixel* tem desvantagens no tratamento de conteúdo rico em informação em imagens de alta resolução espacial, por exemplo, as do satélite Ikonos (resolução espacial até 70cm). Essa desvantagem muitas vezes é traduzida no efeito conhecido como “Sat e pimenta”. Este efeito acontece quando o *pixel* não é maior ou igual aos objetos pesquisados e a área de interesse possui grande heterogeneidade como no caso dos cenários urbanos. A classificação resultante é também uma imagem com grande heterogeneidade (BLASCHKE; LANG; HAY, 2008).

Dentro deste contexto, um novo termo vem sendo cunhado na última década na comunidade internacional de sensoriamento remoto para lidar com a técnica de Análise de Imagens Baseada em Objetos (OBIA).

“O conceito de OBIA primeiro ganhou um interesse generalizado no seio da comunidade GIScience (*Geographic Information Science*) por volta do ano 2000, com o advento do primeiro software comercial para o que foi então denominado ‘Análise de Imagem Orientada a Objeto’. No entanto, há um consenso que OBIA reúne conceitos antigos sobre segmentação, detecção de bordas e classificação que foram utilizados em análise de imagens de sensoriamento remoto há várias décadas” (BLASCHKE; LANG; HAY, 2008).

“O principal propósito da OBIA, no contexto do sensoriamento remoto, é fornecer métodos adequados e automatizados para a análise de imagens de alta resolução espacial (VHSR) descrevendo a realidade da imagem usando as características espectral, textura, espacial e topológica” (LANG, 2008).

“OBIA surgiu como uma alternativa ao paradigma tradicional baseado em *pixel* e é baseado na idéia de que, deslocando as unidades básicas de *pixels* para objetos de imagem, podemos emular (ou exceder) a interpretação visual, fazer melhor utilização da informação espacial implícita nas imagens de sensoriamento remoto, ao mesmo tempo, proporcionar uma maior integração com os vetores do GIS” (HAY; CASTILLA, 2008).

“OBIA assume que podemos identificar entidades nas imagens de sensoriamento remoto que podem estar relacionadas a entidades verdadeiras na paisagem. O primeiro passo neste tipo de análise é a segmentação, a quebra de uma imagem em um conjunto de regiões mutuamente disjuntas que são mais uniformes dentro de si, do que quando comparada com regiões adjacentes. Estas regiões (também conhecido por segmentos) são mais tarde relacionadas a objetos

geográficos (como florestas e lagos) através de alguma classificação baseada em objeto” (HAY; CASTILLA, 2008).

“A análise baseada em objeto tem como princípio dois passos: segmentação/multiresolução e classificação. No primeiro, são criados objetos em diferentes escalas (segmentação em diferentes níveis), conectados entre si, de acordo com critérios de forma e cor. No segundo passo, os objetos passam a se relacionar através da definição da rede hierárquica (herança dos atributos que descrevem a classe) e da rede semântica (estrutura lógica de relação entre as classes). Para a classificação é utilizado o maior grau de pertinência dos objetos à determinada classe por meio da lógica *fuzzy*” (PINHEIRO; KUX, 2005).

2.3 Classificação de imagens

As principais técnicas de classificação de imagens baseiam-se na abordagem *pixel a pixel*, ou seja, cada *pixel* da imagem é analisado para saber se ele pertence ou não a uma determinada classe de interesse. Esta técnica utiliza a resposta espectral dos alvos para classificar o *pixel*. Esta técnica depende da quantidade de bandas espectrais que o sensor é capaz de capturar no momento da aquisição das imagens. Quanto maior a quantidade de bandas capturadas para o mesmo *pixel*, melhor será a discriminação do *pixel* no momento da classificação. Esta característica é conhecida como resolução espectral do sensor. Alguns sensores modernos chegam até 300 bandas, ou seja, para a mesma cena são capturadas 300 imagens.

Figura 11 - Imagem espectral. Adaptado de Short (2009)

Segundo Houaiss (2007), classificar significa: distribuir em classes e nos respectivos grupos, de acordo com um sistema ou método de classificação; ou determinar a classe, ordem, família, gênero e espécie.

Em sensoriamento remoto, usualmente, classificar significa atribuir um número de pixel ou objetos a certa classe, de acordo com a descrição da classe. A descrição da classe é feita pela descrição das propriedades de seus atributos. Os objetos passam então a ser atribuído (classificados) em função do fato deles terem ou não terem essas propriedades.

No que diz respeito aos métodos de classificação, eles podem ser separados basicamente em métodos supervisionados, não-supervisionados ou híbridos. Os métodos supervisionados solicitam do usuário a descrição das classes desejadas, os métodos não-supervisionados são quase sempre independentes do usuário. Os métodos supervisionados têm de ser treinados pelo usuário - geralmente, por amostragem ou pela descrição das propriedades das classes.

Figura 12 - (a) Imagem original (ATECH, 2007) e (b) imagem classificada *pixel a pixel* (RESENDE et al., 2008)

2.3.1 Classificação *Spectral Angle Mapper* (SAM)

“SAM é uma ferramenta que permite um mapeamento rápido da semelhança espectral do espectro da imagem com o espectro de referência” (BOARDMAN, 1993). Os espectros de referência podem ser tanto de laboratório ou de campo, ou extraído a partir da imagem em análise.

“O algoritmo determina a similaridade espectral entre dois espectros pelo cálculo do ângulo entre os dois espectros, tratando-os como vetores em um espaço com dimensionalidade igual ao número de bandas da imagem” (KRUSE et al., 1993).

Uma explicação simplificada por ser dada considerando um espectro de referência e um espectro de teste contendo duas bandas espectrais, estes espectros são representados como dois pontos em um gráfico bidimensional (Veja Figura 13). A linha conectando cada ponto até a origem contém todas as posições possíveis para um dado material, correspondente a faixa iluminação possível. *Pixel* com pouca iluminação cairá próximo da origem em relação a um *pixel* com boa iluminação. O algoritmo SAM generaliza este conceito para um espaço n dimensional que é igual ao número de bandas analisadas.

Segundo Lillesand, Kiefer e Chipman (2007), “[...] para comparar dois espectros, como o espectro de um *pixel* da imagem com o espectro de uma biblioteca espectral, os vetores são definidos no espaço multidimensional e o ângulo entre os vetores calculado. Se o ângulo é menor que um nível de tolerância, os

espectros são considerados iguais, mesmo que um espectro seja mais brilhante do outro”.

Figura 13 - Conceito do SAM. Adaptado de Boardman (1993).

2.3.2 Segmentação

A segmentação é a base da classificação por objetos. É a partir da segmentação que as informações intrínsecas do objeto de forma e textura são calculadas e também a construção dos relacionamentos com os outros objetos é construída.

“Segmentação de imagem significa a partição de uma imagem em regiões significativas baseada no critério de homogeneidade ou heterogeneidade, respectivamente” (HARALICK; SHAPIRO, 1992).

“As técnicas de segmentação podem ser diferenciadas nos seguintes conceitos básicos: orientado a *pixel*, orientado a contorno, orientado a região, orientado a modelo e híbrido” (NEUBERT; HEROLD; MEINEL, 2006).

“Na segmentação de imagem a expectativa é, em muitos casos, ser capaz de extrair automaticamente os objetos de interesse em uma imagem para uma determinada tarefa. No entanto, esta expectativa ignora a considerável semântica que, na maioria dos casos, precisa ser tratada para alcançar resultado satisfatório, ou desenvolver algoritmos altamente específicos aplicáveis apenas a um grupo reduzido de problemas e dados de imagem” (BAATZ; SCHAPE, 2000).

Figura 14 - Imagem segmentada

“A escala dos objetos é uma variável importante que influencia a segmentação de imagens. [...] o parâmetro de escala usado por um classificador orientado a objeto dependerá de um número de fatores, incluindo a resolução do sensor e a escala geral das feições na paisagem que o analista está procurando identificar” (LILLESAND; KIEFER; CHIPMAN, 2007)

2.3.3 Resolução em imagens

O termo resolução em sensoriamento remoto se desdobra na verdade em três diferentes (e independentes) parâmetros: resolução espacial, resolução espectral e resolução radiométrica (CROSTA, 1993).

Resolução espacial refere-se à habilidade do sistema sensor em distinguir e medir os alvos. Esta habilidade baseia-se na projeção geométrica do detector na superfície terrestre, definindo a sua área do campo de visada do instrumento numa certa altitude e num determinado instante. O ângulo definido por esta projeção é denominado de campo de visada instantânea (*Instantaneous Field Of View*, IFOV). O IFOV define a área do terreno focalizada a uma dada altitude pelo instrumento sensor (FLORENZANO, 2002).

Os sistemas sensores têm um específico campo de visada instantâneo (IFOV) ou um campo de visada instantâneo projetado no solo (GIFOV) – ou simplesmente: uma certa resolução espacial (BLASCHKE et al., 2000).

Resolução Espectral é um conceito próprio para os sistemas sensores multiespectrais e hiperespectrais. Segundo Novo (1989), resolução espectral é "uma medida da largura das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade do sinal de retorno".

Resolução Radiométrica refere-se à capacidade do sistema sensor em detectar as variações da radiância espectral recebida. A radiância de cada *pixel* passa por uma codificação digital, obtendo um valor numérico, expresso em bits, denominado de Número Digital (ND). Este valor é facilmente traduzido para uma intensidade visual ou ainda a um nível de cinza, localizado num intervalo finito (0, K-1), onde K é o número de valores possíveis, denominados de níveis de quantização (SCHOWENGERDT, 1983).

Além das resoluções descritas anteriormente, a resolução temporal é também utilizada para descrever a frequência com que determinado sensor recobre a mesma área de interesse. Este conceito é aplicado, principalmente para os sensores orbitais. Apesar de ser possível falar de resolução temporal para um sensor geoestacionário também.

2.4 Lógica fuzzy (Nebulosa)

Lógica *fuzzy* é baseada na teoria dos conjuntos *fuzzy*. Tradicionalmente, uma proposição lógica tem dois extremos: ou é “completamente verdadeiro” ou é “completamente falso”. Entretanto, na lógica *fuzzy*, uma premissa varia em grau de verdade de 0 a 1, o que leva a ser parcialmente verdadeira ou parcialmente falsa.

Na teoria dos conjuntos *fuzzy* existe um grau de pertinência de cada elemento a um determinado conjunto. Com os conjuntos *fuzzy*, podemos definir critérios e graus de pertinência para tais situações. A função característica pode ser generalizada de modo que os valores designados aos elementos do conjunto universo U pertençam ao intervalo de números reais de 0 a 1 inclusive, isto é [0,1].

Figura 15 - Lógica tradicional

Figura 16 - Número *fuzzy*

“Lógica *fuzzy* lida com proposições que podem ser verdadeiras para um certo grau entre 0 e 1. Portanto, um valor da proposição verdade indica o grau de certeza sobre a proposição ser verdadeira” (MCNEILL, 1994). A função de pertinência triangular é a função mais utilizada e prática para representar um número *fuzzy*, mas outras formas podem ser utilizadas também.

Figura 17 - Função de pertinência trapezoidal

Um conjunto *fuzzy* também pode ser representado por uma equação quadrática que produz uma curva contínua. Três formas são possíveis: função S, função PI e a função Z (Figura 18).

Figura 18 - Funções de pertinência S, Pi e Z

2.5 Fuzzy e processamento de imagem

Segundo Blaschke et al. (2000), “[...] métodos que se esforçam para melhorar a precisão da classificação são os utilizando conjuntos fuzzy. Com este conceito cada pixel pode ter pertinência fuzzy com mais de uma classe expressando o seu grau de pertinência para cada classe (valores entre 0 e 1)”.

Sistemas de classificação *fuzzy* se encaixam perfeitamente à manipulação da indefinição na extração de informações em sensoriamento remoto. Parâmetro e modelo de incertezas são considerados no uso de conjuntos *fuzzy* definidos pelas funções de pertinência. Em vez do binário "verdadeiro" e "falso", a lógica *fuzzy* com múltiplos valores permite transições entre a "verdade" e o "falso".

Para uma classificação ter sucesso, a escolha da função de pertinência é crucial. Isso permite a introdução de conhecimento especializado dentro do sistema. Quanto melhor for o conhecimento sobre o sistema real, modelado pela função de pertinência, melhor o resultado da classificação final.

Figura 19 - Exemplos de função de pertinência no software eCognition (DEFINIENS, 2004).

Uma base de regras *fuzzy* é uma combinação de diferentes conjuntos *fuzzy*. Para criar regras *fuzzy* avançadas, conjuntos *fuzzy* podem ser combinados. Um operador *fuzzy* retorna um valor que é obtido a partir da combinação de conjuntos *fuzzy*. Os operadores fundamentais são "e" e "ou". "E" representa o mínimo, o que significa que o valor mínimo de todos os conjuntos define o valor de

retorno. "Ou" representa o valor máximo, o que significa que o valor máximo de todos os conjuntos define o valor de retorno.

Figura 20 - Base de regras *fuzzy* (DEFINIENS, 2004).

2.6 Sensor Hiperespectral

Segundo Gomez (2002), a era hiperespectral começou com o mapeamento aéreo de minerais no final da década de 70 e início dos anos 80. A invenção do *charge-coupled device* (CCD) em 1969 foi um fator chave impulsionador da tecnologia hiperespectral. Em 1989, o maior avanço ocorreu com a chegada do *NASA/JPL Airborne Visible/IR Imaging Spectrometer* (AVIRIS). O sistema AVIRIS, um sensor hiperespectral imageador, coleta imagens em 220 bandas espectrais na faixa de 400 a 2500 nm. Estimulados por este instrumento, muitos outros sensores multiespectral e hiperespectral foram produzidos.

O *Compact Airborne Spectrographic Imager* (CASI) é um espectrômetro imageador. Este sensor hiperespectral detecta uma vasta gama de bandas espectrais estreitas nos comprimentos de ondas do visível e infravermelho próximo.

A faixa espectral coberta pelos 288 canais do sensor CASI varia de 380 a 1050 nm. Possui resolução espectral de 2,4 nm e radiométrica de 14 bits. *Field of View* (FOV) de 40° e *Instantaneous Field of View* (IFOV) de 0,49 mRad. A resolução espacial depende da altura do voo da aeronave.

2.7 Sistema de Monitoramento Aéreo de Baixo Custo (SMABC)

O projeto SMABC é resultado de um Convênio assinado pela Atech - Tecnologias Críticas com a Financiadora de Estudos e Projetos (FINEP) em Dezembro de 2005 com a finalidade de gerar um produto e serviços de monitoramento aéreo de baixo custo, com transmissão de imagens e dados de controle em tempo real, por meio do emprego de aeronave e sistemas terrestres de controle e processamento de dados, a serem explorados comercialmente pela empresa AEROSENSOR.

“O SMABC preenche uma lacuna importante no mercado civil de monitoramento aéreo, pois agrega tecnologias e características não existentes em sistemas e equipamentos civis assemelhados que utilizam aeronaves de médio e pequeno porte, incluindo-se os helicópteros. Estas mesmas tecnologias conferem ao SMABC um grau de automatismo e autonomia que o aproxima dos veículos aéreos não-tripulados” (RODRIGUES; RESENDE; TIMOSZCZUK, 2007).

Os principais subsistemas componentes do SMABC são: o Segmento Aéreo, composto de aeronave do tipo moto-planador adaptada para o transporte de sensores; o Segmento Terrestre, composto de um veículo do tipo furgão adaptado para suportar a eletrônica embarcada e dois postos de operação; os Sensores aeroembarcados, responsáveis pela aquisição de dados; e o Enlace de Dados de alto desempenho, responsável pela comunicação dos dados de imagem e controle entre os Segmentos Aéreo e Terrestre.

Em função da qualidade das imagens geradas, tecnologia, pioneirismo das imagens no mercado nacional e as restrições físicas impostas pela plataforma aérea foi escolhido o sensor hiperespectral (VNIR) CASI 1500 da empresa ITres para ser o sensor imageador do sistema SMABC.

2.8 Pavimentos asfaltados

Pavimento é uma estrutura de múltiplas camadas de espessuras finitas, construída sobre a superfície final de terraplenagem, destinada técnica e economicamente a resistir aos esforços oriundos do tráfego de veículos e do clima, e a propiciar aos usuários melhoria nas condições de rolamento,

com conforto, economia e segurança. Os pavimentos de concreto-cimento são aqueles em que o revestimento é uma placa de concreto de cimento Portland. Os pavimentos asfálticos são aqueles em que o revestimento é composto por uma mistura constituída basicamente de agregados e ligantes asfálticos. É formado por quatro camadas principais: revestimento asfáltico, base, sub-base e reforço do subleito.

Os defeitos de superfície são os danos ou deteriorações na superfície dos pavimentos asfálticos que podem ser identificados a olho nu e classificados segundo uma terminologia normalizada. A finalidade do levantamento dos defeitos da superfície é para poder avaliar o estado de conservação dos pavimentos asfálticos e em caso de necessidade de restauração do pavimento, a análise dos defeitos embasa o diagnóstico do problema para subsidiar uma solução tecnicamente adequada. Em caso de gerência de pavimentos ou de manutenção, o conjunto de defeitos de um dado trecho pode ser resumido por índices que auxiliem na hierarquização de necessidades e alternativas. (BERNUCCI et al., 2008).

Para a definição de alternativas de restauração é necessário o estudo da condição do pavimento existente. Este estudo é precedido por uma avaliação funcional e uma avaliação estrutural. Essas avaliações fornecem dados para análise da condição da superfície do pavimento e de sua estrutura e também para a definição das alternativas de restauração apropriadas.

Na avaliação funcional é verificada a condição da superfície do pavimento, por meio do levantamento e análise de defeitos superficiais, e da condição de irregularidade longitudinal. Os principais defeitos considerados na avaliação funcional são: área trincada e severidade do trincamento, deformações permanentes e irregularidade longitudinal.

Na avaliação estrutural é verificada a condição da estrutura do pavimento de suportar cargas, por meio de levantamentos não-destrutivos pela determinação da deflexão superficial resultante da aplicação de uma carga conhecida.

Ainda segundo Bernucci et al. (2008), os defeitos de pavimentos asfálticos decorrem dos seguintes fatores.

- Erros de projeto. Por exemplo, dificuldade de prever tráfego real, problemas no dimensionamento estrutural, especificação de materiais inexistente ou de difícil disponibilidade no local, aprisionamento de água.
- Erros ou inadequações na seleção de materiais ou na dosagem de materiais. Por exemplo, seleção incorreta de solo para reforço de subleito, seleção imprópria de agregados e de graduação para compor bases e sub-bases, seleção imprópria do tipo de solo ou

dosagem inadequada para solo-brita, dosagem de materiais de materiais estabilizados com cimento ou cal, dentre outros.

- Erros ou inadequações construtivas. Por exemplo, falta de compactação apropriada das camadas, técnica de compactação inadequada, compactação de misturas asfálticas em temperaturas inadequadas, erros nas taxas de imprimação do impermeabilizante ou ligante.
- Erros ou inadequações nas alternativas de conservação e manutenção. Por exemplo, reforço de revestimento asfáltico delgado e rígido sobre pavimento muito trincado, uso de tratamentos superficiais delgados para redução de irregularidade, uso de revestimento asfálticos permeáveis sobre pavimento trincado sem tratamento de impermeabilização.

Os tipos de defeitos catalogados pela norma brasileira e que são considerados para cálculo de indicador de qualidade da superfície do pavimento (IGG – índice de Gravidade Global) são: fendas (F); afundamentos (A); corrugação e ondulações transversais (O); exsudação (EX); desgaste ou desagregação (D); panela ou buraco (P); e remendos (R).

2.8.1 Classificação e definição dos defeitos do pavimento

Segundo a NORMA DNIT 005/2003, os defeitos nos pavimentos flexíveis e semi-rígidos são classificados e definidos da seguinte forma:

2.8.1.1 Fenda (F)

Qualquer descontinuidade na superfície do pavimento, que conduza a aberturas de menor ou maior porte, apresentando-se sob diversas formas. A Fenda pode ser classificada em fissura ou trinca. Fissura é uma fenda de largura capilar existente no revestimento, posicionada longitudinal, transversal ou obliquamente ao eixo da via, somente perceptível a vista desarmada de uma distância inferior a 1,50 m. Trinca é uma fenda existente no revestimento, facilmente visível a vista desarmada, com abertura superior à da fissura, podendo apresentar-se sob a forma

de trinca isolada ou trinca interligada. As trincas podem ser classificadas em trinca isolada ou trincas interligadas. As trincas isoladas podem ser transversal, longitudinal ou retração. A trinca transversal é uma trinca isolada que apresenta direção predominantemente ortogonal ao eixo da via. Quando apresentar extensão de até 100 cm é denominada trinca transversal curta. Quando a extensão for superior a 100 cm denomina-se trinca transversal longa. A trinca longitudinal é uma trinca isolada que apresenta direção predominantemente paralela ao eixo da via. Quando apresentar extensão de até 100 cm é denominada trinca longitudinal curta. Quando a extensão for superior a 100 cm denomina-se trinca longitudinal longa. A trinca de retração é uma trinca isolada não atribuída aos fenômenos de fadiga e sim aos fenômenos de retração térmica ou do material do revestimento ou do material de base rígida ou semi-rígida subjacentes ao revestimento trincado. As trincas interligadas podem ser do tipo “Couro de Jacaré” ou tipo “Bloco”. As trincas do tipo “Couro de Jacaré” são um conjunto de trincas interligadas sem direções preferenciais, assemelhando-se ao aspecto de couro de jacaré. Essas trincas podem apresentar, ou não, erosão acentuada nas bordas. As trincas do “Bloco” são trincas interligadas caracterizadas pela configuração de blocos formados por lados bem definidos, podendo, ou não, apresentar erosão acentuada nas bordas.

2.8.1.2 Afundamento (A)

Deformação permanente caracterizada por depressão da superfície do pavimento, acompanhada, ou não, de solevamento, podendo apresentar-se sob a forma de afundamento plástico ou de consolidação. Afundamento plástico é causado pela fluência plástica de uma ou mais camadas do pavimento ou do subleito, acompanhado de solevamento. Quando ocorre em extensão de até 6 m é denominado afundamento plástico local; quando a extensão for superior a 6 m e estiver localizado ao longo da trilha de roda é denominado afundamento plástico da trilha de roda. Afundamento de consolidação é causado pela consolidação diferencial de uma ou mais camadas do pavimento ou subleito sem estar acompanhado de solevamento. Quando ocorre em extensão de até 6 m é denominado afundamento de consolidação local; quando a extensão for superior a 6m e estiver localizado ao longo da trilha de roda é denominado afundamento de consolidação da trilha de roda.

2.8.1.3 Ondulação ou Corrugação (O)

Deformação caracterizada por ondulações ou corrugações transversais na superfície do pavimento.

2.8.1.4 Escorregamento (E)

Deslocamento do revestimento em relação à camada subjacente do pavimento, com aparecimento de fendas em forma de meia-lua.

2.8.1.5 Exsudação (EX)

Excesso de ligante betuminoso na superfície do pavimento, causado pela migração do ligante através do revestimento.

2.8.1.6 Desgaste (D)

Efeito do arrancamento progressivo do agregado do pavimento, caracterizado por aspereza superficial do revestimento e provocado por esforços tangenciais causados pelo tráfego.

2.8.1.7 Panela ou buraco (P)

Cavidade que se forma no revestimento por diversas causas (inclusive por falta de aderência entre camadas superpostas, causando o desprendimento das camadas), podendo alcançar as camadas inferiores do pavimento, provocando a desagregação dessas camadas.

2.8.1.8 Remendo (R)

Panela preenchida com uma ou mais camadas de pavimento na operação denominada de “tapa-buraco”. Remendo profundo é aquele em que há substituição do revestimento e, eventualmente, de uma ou mais camadas inferiores do pavimento. Usualmente, apresenta forma retangular. Remendo superficial é a correção, em área localizada, da superfície do revestimento, pela aplicação de uma camada betuminosa.

Tabela 3 - Quadro resumo dos defeitos dos pavimentos – Codificação e Classificação.

FENDAS				CODIFICAÇÃO	CLASSE DAS FENDAS		
Fissuras				FI	-	-	-
Trincas no revestimento geradas por deformação permanente excessiva e/ou decorrentes do fenômeno de fadiga	Trincas Isoladas	Transversais	Curtas	TTC	FC-1	FC-2	FC-3
			Longas	TTL	FC-1	FC-2	FC-3
		Longitudinais	Curtas	TLC	FC-1	FC-2	FC-3
			Longas	TLL	FC-1	FC-2	FC-3
	Trincas Interligadas	"Jacaré"	Sem erosão acentuada nas bordas das trincas	J	-	FC-2	-
			Com erosão acentuada nas bordas das trincas	JE	-	-	FC-3
Trincas no revestimento não atribuídas ao fenômeno de fadiga	Trincas Isoladas	Devido à retração térmica ou dissecação da base (solo-cimento) ou do revestimento		TRR	FC-1	FC-2	FC-3
	Trincas Interligadas	"Bloco"	Sem erosão acentuada nas bordas das trincas	TB	-	FC-2	-
			Com erosão acentuada nas bordas das trincas	TBE	-	-	FC-3

Fonte: NORMA DNIT 005/2003 – TER.

Tabela 4 - Quadro resumo dos defeitos dos pavimentos – Codificação e Classificação (Cont.).

OUTROS DEFEITOS				CODIFICAÇÃO
Afundamento	Plástico	Local	Devido à fluência plástica de uma ou mais camadas do pavimento ou do subleito	ALP
		da Trilha	Devido à fluência plástica de uma ou mais camadas do pavimento ou do subleito	ATP
	De Consolidação	Local	Devido à consolidação diferencial ocorrente em camadas do pavimento ou do subleito	ALC
		da Trilha	Devido à consolidação diferencial ocorrente em camadas do pavimento ou do subleito	ATC
Ondulação/Corrugação - Ondulações transversais causadas por instabilidade da mistura betuminosa constituinte do revestimento ou da base				O
Escorregamento (do revestimento betuminoso)				E
Exsudação do ligante betuminoso no revestimento				EX
Desgaste acentuado na superfície do revestimento				D
"Painéis" ou buracos decorrentes da desagregação do revestimento e às vezes de camadas inferiores				P
Remendos			Remendo Superficial	RS
			Remendo Profundo	RP

Fonte: NORMA DNIT 005/2003 – TER.

NOTA 1: Classe das trincas isoladas

FC-1: são trincas com abertura superior à das fissuras e menores que 1,0mm.

FC-2: são trincas com abertura superior a 1,0mm e sem erosão nas bordas.

FC-3: são trincas com abertura superior a 1,0mm e com erosão nas bordas.

NOTA 2: Classe das trincas interligadas

As trincas interligadas são classificadas como FC-3 e FC-2 caso apresentem ou não erosão nas bordas.

2.8.2 Avaliação objetiva de superfície pela determinação do IGG

O Índice de Gravidade Global (IGG) é um indicador de qualidade da superfície do pavimento.

O DNIT 006/2003 – PRO (DNIT) estabelece um método de levantamento sistemático de defeitos e atribuição do Índice de Gravidade Global (IGG), que pode ser empregado em projetos de reforço. Para sistemas de gerência de manutenção empregas-se geralmente o DNIT 007/2003 – PRO (DNIT).

Para determinação do IGG, as superfícies de avaliação devem ser localizadas do seguinte modo: nas rodovias de pista simples, a cada 20m alternados em relação ao eixo da pista de rolamento (40 m em 40 m em cada faixa de tráfego); nas rodovias com pista dupla, a cada 20 m, na faixa de tráfego mais solicitada de cada pista (DNIT 006/2003-PRO).

A superfície de avaliação corresponde a 3m antes e 3m após cada uma das estacas demarcadas, totalizando em cada estação uma área correspondente a 6m de extensão e largura igual a da faixa a ser avaliada (BERNUCCI et al., 2008).

Em cada superfície de avaliação deve ser anotada a presença de qualquer ocorrência (defeito) no pavimento, de acordo com a norma DNIT 005/2003-TER. As anotações devem ser feitas utilizando-se da planilha “Formulário de Inventário do estado da superfície do pavimento” definida no Anexo B da norma DNIT 006/2003-PRO. Para as ocorrências inventariadas devem ser calculadas as frequências absolutas e relativas.

A frequência absoluta (f_a) corresponde ao número de vezes em que a ocorrência foi verificada. A frequência relativa (f_r) é obtida através da fórmula:

$$f_r = \frac{f_a \cdot 100}{n} \quad (2)$$

onde:

f_r - frequência relativa;

f_a - frequência absoluta;

n - número de estações inventariadas.

Para cada uma das ocorrências inventariadas, deve ser calculado o Índice de Gravidade Individual (IGI), pela fórmula:

$$IGI = f_r \cdot f_p \quad (3)$$

onde:

f_r - frequência relativa;

f_p - fator de ponderação, obtido de acordo com a Tabela 5.

O Índice de Gravidade Global (IGG) é obtido por meio da fórmula:

$$IGG = \sum IGI \quad (4)$$

onde:

$\sum IGI$ - somatório dos Índices de Gravidade Individuais, calculados de acordo com o estabelecido no item 7.3. O Índice de Gravidade Global deve ser calculado para cada trecho homogêneo.

A partir do número calculado do IGG é possível conferir ao pavimento inventariado um conceito que retrate o grau de degradação atingido (veja Tabela 6).

Tabela 5 - Valor do fator de ponderação dos tipos de ocorrência.

Ocorrência Tipo	Codificação de ocorrências de acordo com a Norma DNIT 005/2002-TER "Defeitos nos pavimentos flexíveis e semi-rígidos – Terminologia" (ver item 6.4 e Anexo D)	Fator de Ponderação f_p
1	Fissuras e Trincas Isoladas (FI, TTC, TTL, TLC, TLL e TRR)	0,2
2	FC-2 (J e TB)	0,5
3	FC-3 (JE e TBE) NOTA: Para efeito de ponderação quando em uma mesma estação forem constatadas ocorrências tipos 1, 2 e 3, só considerar as do tipo 3 para o cálculo da frequência relativa em percentagem (fr) e Índice de Gravidade Individual (IGI); do mesmo modo, quando forem verificadas ocorrências tipos 1 e 2 em uma mesma estação, só considerar as do tipo 2.	0,8
4	ALP, ATP e ALC, ATC	0,9
5	O, P, E	1,0
6	EX	0,5
7	D	0,3
8	R	0,6

Fonte: DNIT 006/2003-PRO.

Tabela 6 - Conceitos de degradação do pavimento em função do IGG.

Norma DNIT 06/2003		Norma DNER 08/1994	
Conceito	Limites	Conceito	Limites
Ótimo	$0 < IGG \leq 20$		
Bom	$20 < IGG \leq 40$	Bom	$0 < IGG \leq 20$
Regular	$40 < IGG \leq 80$	Regular	$20 < IGG \leq 80$
Ruim	$80 < IGG \leq 160$	Mau	$80 < IGG \leq 150$
Péssimo	$IGG > 160$	Péssimo	$IGG > 150$

Fonte: BERNUCCI et al., 2008.

2.8.3 Levantamento Visual Contínuo (LVC)

A NORMA DNIT 008/2003 – PRO fixa as condições exigíveis na avaliação da superfície de pavimentos flexíveis e semi-rígidos pelo processo de Levantamento Visual Contínuo (LVC) determinando-se o Índice de Condição de Pavimentos Flexíveis (ICPF), ao mesmo tempo em que proporciona também os elementos necessários para o cálculo do Índice de Gravidade Global Expedito (IGGE) e do Índice do Estado de Superfície do Pavimento (IES).

O método de levantamento visual contínuo utiliza um veículo equipado com velocímetro e odômetro calibrados para aferição da velocidade de operação e das distâncias percorridas. A norma estipula que a equipe seja constituída de dois técnicos além do motorista do veículo. Segundo a NORMA DNIT 008/2003 – PRO, “o veículo deve ser operado a uma velocidade média aproximada de 40 km/h percorrendo a rodovia em um único sentido (rodovia de 2 faixas de tráfego). No caso de rodovias com 2 pistas de cada lado o levantamento será feito para cada pista em separado”. O pavimento que será analisado deverá ser dividido em trechos de no mínimo 1 km e no máximo 6 km.

Os formulários são preenchidos com os dados de identificação da rodovia e os dados observados em cada trecho do pavimento. A frequência de defeitos é registrada utilizando-se de um código de letras: “A”, “M” ou “B” conforme a estimativa da qualidade e da porcentagem de ocorrência do defeito de acordo com a Tabela 7.

Tabela 7 – Frequência de defeitos para o LVC.

Panelas (P) e Remendos (R)		
Código	Frequência	Quant./km
A	Alta	≥ 5
M	Média	2 – 5
B	Baixa	≤ 2
Demais defeitos		
Código	Frequência	% por km
A	Alta	≥ 50
M	Média	50 – 10
B	Baixa	≤ 10

Fonte: DNIT 008/2003-PRO.

Segundo a NORMA DNIT 008/2003 – PRO, o Índice da Condição do Pavimento Flexível é estimado com base na avaliação visual do pavimento, classificando a superfície do segmento segundo os conceitos mostrados na Tabela 8. O ICPF final é a média dos valores anotados em cada trecho.

Tabela 8 – Conceitos do ICPF.

CONCEITO	DESCRIÇÃO	ICPF
Ótimo	Necessita apenas de conservação rotineira	5-4
Bom	Aplicação de lama asfáltica – desgaste superficial, trincas não muito severas em áreas não muito extensas	4-3
Regular	Correção de pontos localizados ou recapeamento - pavimento trincado, com “panelas” e remendos pouco freqüentes e com irregularidade longitudinal ou transversal.	3-2
Ruim	Recapeamento com correções prévias - defeitos generalizados com correções prévias em áreas localizadas - remendos superficiais ou profundos.	2-1
Péssimo	Reconstrução - defeitos generalizados com correções prévias em toda a extensão. degradação do revestimento e das demais camadas - infiltração de água e descompactação da base.	1-0

Fonte: DNIT 008/2003-PRO.

O Índice de Gravidade Global Expedito (IGGE) é calculado através da frequência dos defeitos e seus respectivos pesos. Os defeitos são agrupados em três conjuntos: trincas, deformações e panelas/remendos.

$$IGGE = (P_t \times F_t) + (P_{oap} \times F_{oap}) + (P_{pr} \times F_{pr}) \quad (5)$$

onde:

P_t e F_t – Frequência e Peso do conjunto de trincas;

P_{oap} e F_{oap} – Frequência e Peso do conjunto de deformações;

P_{pr} e F_{pr} – Frequência (quantidade por km) e Peso do conjunto de panelas e remendos;

Os pesos de cada grupo variam em função da frequência de ocorrência de defeitos, conforme apresentado na Tabela 9.

Tabela 9 – Pesos para cálculo IGGE.

Painéis (P) e Remendos (R)				
Código	Frequência	Quant./km	Gravidade	Ppr
A	Alta	≥ 5	3	1,00
M	Média	2 – 5	2	0,80
B	Baixa	≤ 2	1	0,70

Demais defeitos (trincas)				
Código	Frequência	% por km	Gravidade	Pt
A	Alta	≥ 50	3	0,65
M	Média	50 – 10	2	0,45
B	Baixa	≤ 10	1	0,30

Demais defeitos (deformações)				
Código	Frequência	% por km	Gravidade	Poap
A	Alta	≥ 50	3	1,00
M	Média	50 – 10	2	0,70
B	Baixa	≤ 10	1	0,60

Fonte: DNIT 008/2003-PRO.

O IES é calculado em função do ICPF e do IGGE conforme Tabela 10.

Tabela 10 – Índice do Estado da Superfície do pavimento.

DESCRIÇÃO	IES	CÓDIGO	CONCEITO
$IGGE \leq 20$ e $ICPF > 3,5$	0	A	Ótimo
$IGGE \leq 20$ e $ICPF \leq 3,5$	1	B	Bom
$20 \leq IGGE \leq 40$ e $ICPF > 3,5$	2		
$20 \leq IGGE \leq 40$ e $ICPF \leq 3,5$	3	C	Regular
$40 \leq IGGE \leq 60$ e $ICPF > 2,5$	4		
$40 \leq IGGE \leq 60$ e $ICPF \leq 2,5$	5	D	Ruim
$60 \leq IGGE \leq 90$ e $ICPF > 2,5$	7		
$60 \leq IGGE \leq 90$ e $ICPF \leq 2,5$	8	E	Péssimo
$IGGE > 90$	10		

Fonte: DNIT 008/2003-PRO.

3 Recursos Empregados na Pesquisa

3.1 Área de Estudo

Durante o decorrer da pesquisa, a obtenção de imagens que atendessem aos objetivos traçados pelo estudo em termos de resolução espectral, espacial, temporal e área de estudo que houvesse incidência dos defeitos do asfalto foi sempre um grande desafio a ser vencido.

O melhor conjunto de dados que permitiu o exercício da metodologia proposta foi o conjunto de imagens adquiridas em fevereiro de 2010 na região de Sorocaba, São Paulo – SP. Outros conjuntos de dados foram analisados, mas não apresentaram informações suficientes para o desenvolvimento da pesquisa, como foi o caso das imagens da região da cidade de Mogiguaçu, São Paulo - SP ($22^{\circ} 21' 22''$ S $46^{\circ} 58' 04''$ W, $22^{\circ} 21' 57''$ S $46^{\circ} 57' 23''$ W) que possuía boa resolução espectral, mas não possuía resolução espacial (75 cm / pixel) suficiente para avaliar a metodologia proposta.

Desta forma, a área de estudo foi delimitada em função da disponibilidade da informação. Esta área foi levantada a partir de um voo de oportunidade quando a aeronave realizava outra missão de levantamento.

A área de estudo está localizada na área urbana do município de Sorocaba, cortada pela a Rodovia Raposo Tavares, SP-270, dentro do polígono envolvente de pontos ($23^{\circ} 31' 47''$ S $47^{\circ} 28' 08''$ W), ($23^{\circ} 32' 26''$ S $47^{\circ} 30' 12''$ W), ($23^{\circ} 31' 41''$ S $47^{\circ} 26' 14''$ W) e ($23^{\circ} 31' 13''$ S $47^{\circ} 26' 28''$ W).

Figura 21 – Área de Estudo, Sorocaba, São Paulo – SP.

3.2 Imagens do Sensor CASI-1500

O conjunto de dados é formado por quatro imagens do sensor CASI-1500 adquiridas pela plataforma SMABC em 03 de fevereiro de 2010. Imagens 01, 02, 03 e 04.

As imagens 01 e 02 (Figura 22 e Figura 23) são imagens com 24 bandas espectrais contínuas de 380,1 nm até 1.033,1 nm, resolução espacial de 50 cm por pixel, 14 bits de resolução radiométrica.

As imagens 03 e 04 (Figura 24 e Figura 25) são imagens com 8 bandas espectrais contínuas de 380,1 nm até 1.033,1 nm, resolução espacial de 25 cm por pixel, 14 bits de resolução radiométrica.

Todas as imagens foram registradas e geometricamente corrigidas pelo software de pós processamento do CASI-1500 em função da capacidade do sensor de registrar durante a aquisição das mesmas as informações de posicionamento DGPS e atitude da aeronave. Os valores dos pixels das imagens estão em radiância.

Nenhuma das imagens sofreu correção atmosférica

Tabela 11 – Detalhamento das bandas espectrais das imagens do conjunto de dados.

# Banda	Imagem 01	Imagem 02	Imagem 03	Imagem 04
Banda 1	380.1nm +/- 14.1nm	380.1nm +/- 14.1nm	408.4nm +/- 42.4nm	408.4nm +/- 42.4nm
Banda 2	408.3nm +/- 14.1nm	408.3nm +/- 14.1nm	493.4nm +/- 42.5nm	493.4nm +/- 42.5nm
Banda 3	436.7nm +/- 14.2nm	436.7nm +/- 14.2nm	578.5nm +/- 42.6nm	578.5nm +/- 42.6nm
Banda 4	465.0nm +/- 14.2nm	465.0nm +/- 14.2nm	663.8nm +/- 42.7nm	663.8nm +/- 42.7nm
Banda 5	493.3nm +/- 14.2nm	493.3nm +/- 14.2nm	749.1nm +/- 42.7nm	749.1nm +/- 42.7nm
Banda 6	521.7nm +/- 14.2nm	521.7nm +/- 14.2nm	834.5nm +/- 42.6nm	834.5nm +/- 42.6nm
Banda 7	550.1nm +/- 14.2nm	550.1nm +/- 14.2nm	919.7nm +/- 42.6nm	919.7nm +/- 42.6nm
Banda 8	578.5nm +/- 14.2nm	578.5nm +/- 14.2nm	1004.8nm +/- 42.5nm	1004.8nm +/- 42.5nm
Banda 9	606.9nm +/- 14.2nm	606.9nm +/- 14.2nm		
Banda 10	635.4nm +/- 14.2nm	635.4nm +/- 14.2nm		
Banda 11	663.8nm +/- 14.2nm	663.8nm +/- 14.2nm		
Banda 12	692.3nm +/- 14.2nm	692.3nm +/- 14.2nm		
Banda 13	720.7nm +/- 14.2nm	720.7nm +/- 14.2nm		
Banda 14	749.1nm +/- 14.2nm	749.1nm +/- 14.2nm		
Banda 15	777.6nm +/- 14.2nm	777.6nm +/- 14.2nm		
Banda 16	806.0nm +/- 14.2nm	806.0nm +/- 14.2nm		
Banda 17	834.5nm +/- 14.2nm	834.5nm +/- 14.2nm		
Banda 18	862.9nm +/- 14.2nm	862.9nm +/- 14.2nm		
Banda 19	891.3nm +/- 14.2nm	891.3nm +/- 14.2nm		
Banda 20	919.7nm +/- 14.2nm	919.7nm +/- 14.2nm		
Banda 21	948.1nm +/- 14.2nm	948.1nm +/- 14.2nm		
Banda 22	976.4nm +/- 14.2nm	976.4nm +/- 14.2nm		
Banda 23	1004.8nm +/- 14.2nm	1004.8nm +/- 14.2nm		
Banda 24	1033.1nm +/- 14.2nm	1033.1nm +/- 14.2nm

Figura 22 – Imagem 01 com 24 bandas espectrais e 50 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).

Figura 23 – Imagem 02 com 24 bandas espectrais e 50 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).

Figura 24 – Imagem 03 com 8 bandas espectrais e 25 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).

Figura 25 – Imagem 04 com 8 bandas espectrais e 25 cm resolução espacial da Área de Estudo, Sorocaba, São Paulo – SP (ATECH, 2010).

3.3 Programa ENVI

O software ENVI é uma poderosa ferramenta de processamento e análise de imagens. Foi utilizado extensivamente durante o desenvolvimento de toda a pesquisa. Dentre outras operações, foi utilizado para a manipulação das imagens hiperespectrais, classificação SAM, filtros espaciais, criação da biblioteca espectral, geração das componentes principais, cálculo das matrizes de erro. A versão utilizada o software ENVI foi a 4.2.

3.4 Programa eCognition

Definiens Developer é um ambiente integrado de desenvolvimento rápido para soluções de análise de imagens. A versão utilizada foi a 7.0. Este ambiente de desenvolvimento engloba um conjunto de ferramentas integradas, dentro das quais está o Definiens eCognition Server denominado neste trabalho somente de eCognition. As duas principais operações realizadas com o eCognition foram a segmentação denominada de multiresolução e a classificação por objetos.

4 Metodologia

A utilização de imagens hiperespectrais e com alta resolução espacial no monitoramento das condições dos pavimentos asfaltados requer um conjunto de etapas de processamento e adequação das informações de entrada para produção dos resultados esperados. Neste capítulo é apresentada a metodologia para alcançar os objetivos deste trabalho.

Figura 26 - Visão geral da metodologia para monitoramento da condição dos pavimentos asfaltados a partir de imagens hiperespectrais e de alta resolução espacial

A Figura 26 apresenta a visão geral da metodologia empregada para o monitoramento da condição dos pavimentos asfaltados a partir de imagens hiperespectrais e de alta resolução espacial. Na Figura 26, os processos estão representados por retângulos e os dados de entrada e saída estão representados pelos paralelogramos.

A partir de uma imagem hiperespectral, o objetivo é criar índices de qualidade que permitam mensurar a condição dos pavimentos asfaltados.

A metodologia tem com base dois processos principais: Detectar Asfalto e Classificação dos Defeitos do Asfalto.

4.1 Processo Detectar Asfalto

Para realizar a classificação e a identificação dos defeitos do asfalto, o primeiro passo é distinguir na imagem original o que é asfalto. Este passo, por si só, já é um grande esforço dentro da área de sensoriamento remoto e tratamento de imagens, principalmente, quando as imagens são de áreas urbanas. Imagens de área urbana, adquiridas em alta resolução, apresentam grande heterogeneidade, ou seja, na mesma cena há um grande número de feições. Os processos tradicionais de classificação baseado em *pixel* com poucas bandas espectrais não são eficientes para identificação e delimitação dos objetos da imagem, principalmente para o caso do asfalto que se confunde com outros materiais escuros da cena em análise, tais como: telhados de amianto, sombra, estacionamentos em brita, etc. Com o objetivo de melhorar a eficiência na identificação do asfalto nas imagens hiperespectrais de alta resolução espacial, a metodologia da Figura 27 foi proposta. Esta metodologia combina a técnica de classificação por *pixel*, onde a natureza da resposta espectral dos alvos é considerada, com a técnica de classificação baseada em objetos que além das informações espectrais leva em consideração os aspectos espaciais e a morfologia dos objetos que estão sob análise. A combinação destas duas técnicas produz uma eficiência maior quando comparada com aplicação isolada destas duas técnicas na solução do mesmo problema. A Figura 27 é o detalhamento do processo Detectar Asfalto apresentado na Figura 26.

Na primeira fase da detecção do asfalto é feita a classificação supervisionada da imagem utilizando-se o algoritmo *Spectral Angle Mapper* (SAM). O SAM é uma classificação baseada fisicamente no espectro, usa o ângulo n -dimensional para comparar o *pixel* com o espectro de referência (a classe). O algoritmo determina a similaridade entre os dois espectros calculando o ângulo entre eles, tratando-os como vetores em um espaço dimensional igual ao número de bandas da imagem (BOARDMAN, 1993). Foi utilizado o software ENVI 4.2 para a execução do algoritmo SAM. Sendo o SAM um algoritmo de classificação

supervisionada, este por sua vez, necessita de referências ou amostras para que a classificação seja realizada. Uma forma de fornecer os padrões espectrais de referência é através da biblioteca espectral. Esta biblioteca descreve o comportamento espectral dos alvos de interesse, ou seja, neste trabalho, os alvos de interesse são os diversos tipos de asfalto. Cada alvo possui sua curva espectral registrada na biblioteca, e esta curva é utilizada no momento da classificação pelo algoritmo SAM.

Figura 27 - Metodologia para detecção e separação do asfalto em imagens hiperespectrais

Após o término da classificação baseada em *pixel* realizada pelo algoritmo SAM, uma imagem contendo somente a classe asfalto é gerada. Essa imagem é uma imagem de uma só banda que descreve a classe asfalto da imagem hiperespectral original. Mesmo com a utilização de uma imagem com alto número de bandas espectrais, o resultado da classificação apresenta pequenas confusões com outros alvos, veja Figura 28.

Figura 28 - Imagem com informação de asfalto resultado do algoritmo de classificação supervisionada SAM

A segunda fase do processo de detecção é composta de filtros espaciais que são aplicados a imagens com objetivo de agrupar áreas similares adjacentes (pós processamento de Clump), retirar grupos de pixels isolados (pós processamento de Sieve) e suavizar áreas classificadas (filtro de convolução média). A ordem e a importância da aplicação destes filtros foram estudadas para as imagens utilizadas nesta pesquisa.

A terceira fase do processo de detecção do asfalto é realizada para melhorar o resultado obtido pela classificação baseada em *pixel* apresentada na Figura 28. A imagem asfalto da Figura 28 é a entrada para a etapa de classificação baseada em objeto. Nesta etapa, o objetivo é remover os objetos da imagem que foram classificados erroneamente na etapa anterior, com a classificação baseada em objetos é possível fazer a análise espacial dos objetos.

Pela natureza geométrica do objeto em estudo, o asfalto, pode-se concluir que objetos isolados na imagem classificada não devem ser tratados como pavimento de rua, pois um objeto asfalto qualquer da imagem deve ser vizinho de outro objeto asfalto mantendo os aspectos de continuidade intrínsecos das ruas pavimentadas.

Figura 29 – Classes utilizadas na classificação por objetos para remoção de áreas classificadas erroneamente como asfalto.

Para esta fase foi utilizado o software eCognition que realiza a classificação baseada em objeto. Para remoção dos objetos isolados na imagem que não são asfalto foram criadas três classes: Asfalto, NaoEAsfalto e IlhaAsfalto. A classe Asfalto e a classe NaoEAsfalto foram definidas pelos valores espectrais do objeto. A classe IlhaAsfalto foi definida pelos critérios de vizinhança. O objeto para ser da classe IlhaAsfalto deve inicialmente pertencer a classe Asfalto e ser cercada pela classe NaoEAsfalto. Após a classificação, os objetos das classes IlhaAsfalto e NaoEAsfalto são descartados, mantendo-se somente os objetos da classe Asfalto.

Figura 30 - Imagem com informação de asfalto resultado do algoritmo de classificação baseada em objetos

A partir do resultado da classificação baseada em objetos, Figura 30, é realizada uma transformação na imagem utilizando do software ENVI 4.2 para que

seja gerada uma máscara. Esta máscara será aplicada na imagem hiperespectral original. A máscara funciona como uma ferramenta de recorte, geralmente é uma imagem binária que possui somente os valores: 0 e 1. Quando a máscara é aplicada sobre outra imagem, somente os *pixels* coincidentes com os valores 1 da máscara são preservados. Assim é possível separar as regiões de asfalto na imagem hiperespectral original.

4.2 Classificação dos Defeitos do Asfalto

A segunda etapa da metodologia é o processo de Classificação dos Defeitos do Asfalto. Esta etapa utiliza as imagens geradas pelo processo de detecção do asfalto. Duas linhas de investigação e análise das imagens foram trabalhadas. A primeira utilizou a imagem hiperespectral na sua forma original e a segunda linha com a redução da dimensionalidade utilizando a Análise de Componente Principal (PCA). Os resultados finais destas duas linhas de investigação foram comparados no intuito de verificar os impactos da redução da dimensionalidade no produto final.

Nesta fase do processo foram investigados quais os parâmetros de segmentação que melhor atendem ao objetivo do trabalho, para tanto foram gerados cenários de comparação para cada conjunto de valor de segmentação comparando os resultados finais.

Esta etapa de classificação baseia-se prioritariamente na geometria dos objetos utilizando as ferramentas e medidas disponíveis no software de análise baseado em objeto, procurando encontrar os padrões existentes nos defeitos do asfalto.

Importante ressaltar, na Tabela 5 que descreve o fator de ponderação das ocorrências para o cálculo do IGI, as ocorrências que possuem o maior fator de ponderação são aquelas que possuem a maior probabilidade de serem detectadas na imagem (O, P, E, JE, TBE e R), com exceção dos afundamentos que não devem aparecer nas imagens por se tratar de imagens adquiridas de uma tomada superior sem nenhuma informação de elevação.

Figura 31 - Metodologia para classificação dos defeitos do asfalto

O índice de cada categoria será calculado somando-se a área de cada objeto classificado como pertencente ao defeito, dividido pela soma da área dos objetos classificados como asfalto para uma determinada região.

$$I_{cat} = \frac{\sum \text{área}(O_{cat})}{\sum \text{área}(O_{asfalto})} \quad (6)$$

Onde:

I_{cat} = Índice da categoria de defeitos em análise

O_{cat} = Objetos classificados como sendo da categoria de defeitos em análise

$O_{asfalto}$ = Objetos classificados como asfalto

Da mesma forma que é feito o cálculo do IGG ou IGGE pelo método convencional é feita uma soma ponderada dos valores dos I_{cat} levantados a partir das imagens. Assim, ao final, temos um IGG' ou IGGE' calculados por imagem que podem ser comparado com o IGG ou IGGE calculados pelo método convencional respectivamente.

5 Resultados

5.1 Áreas de Interesse (AOI)

O processamento computacional de imagens hiperespectrais geralmente é um processamento lento que pode levar várias horas para se conseguir realizar um algoritmo de classificação ou uma operação sobre uma imagem que está sendo analisada. No caso desta pesquisa, as imagens além de possuírem várias bandas espectrais possuem também alta resolução espacial (25cm e 50cm), esta quantidade de informação nas imagens faz com que os arquivos sejam grandes e que o processamento pelos softwares especialistas seja lento, mesmo em máquinas modernas. Durante o desenvolvimento de qualquer pesquisa, principalmente sensoriamento remoto, sempre existe a necessidade de realizar a mesma operação várias vezes alterando e/ou modificando parâmetros de entradas para observar o comportamento do resultado esperado.

Para minimizar o esforço computacional necessário nas etapas de estudo e validação da metodologia, foram escolhidas áreas de interesse que fossem representativas de todo o conjunto e que possuísem informações de defeitos nos pavimentos.

A seleção das áreas de interesse foi feita a partir da análise visual com o objetivo de selecionar áreas significativas obedecendo aos seguintes critérios:

- Área com informação urbana;
- Área com informação rural¹;
- Área com 8 bandas espectrais;
- Área com 24 bandas espectrais;
- Área com resolução espacial de 25 cm;
- Área com resolução espacial de 50 cm;

¹ As imagens disponíveis são de áreas urbanas. No entanto, existem trechos de rodovias nas imagens que estão circundadas de vegetação que são próximas de um cenário rural.

- Áreas com menos ruídos ou defeitos de imagens provocados pelo sensor;
- Por último, áreas com defeitos do asfalto que foram identificadas em função da pesquisa de campo.

Figura 32 – Área de Interesse – 01, resolução espacial 25 cm e 8 bandas espectrais, amostra da imagem 03 (Figura 24) (ATECH, 2010).

Figura 33 – Área de Interesse – 02, resolução espacial 25 cm e 8 bandas espectrais, amostra da imagem 03 (Figura 24) (ATECH, 2010).

Figura 34 – Área de Interesse – 03, resolução espacial 25 cm e 8 bandas espectrais, amostra da imagem 03 (Figura 24) (ATECH, 2010).

Figura 35 – Área de Interesse – 06, resolução espacial 50 cm e 24 bandas espectrais, amostra da imagem 02 (Figura 23) (ATECH, 2010).

Figura 36 – Área de Interesse – 08, resolução espacial 50 cm e 24 bandas espectrais, amostra da imagem 02 (Figura 23) (ATECH, 2010).

A AOI-01 é uma imagem de uma área urbana dividida pela Rodovia Raposo Tavares, SP-270. Nesta área foi possível estudar o comportamento da metodologia tanto para rodovia quanto para uma parte urbana.

A AOI-02 é uma imagem da rodovia com vegetação e pouca construção ao redor. Para a metodologia, exemplifica as rodovias espalhadas na zona rural, onde a rodovia está circundada de vegetação ou solo exposto. Também, durante a pesquisa de campo, foi verificado que a alça de acesso possuía defeitos do tipo remendo e trincas em blocos que poderiam ser investigados com as imagens em questão.

A AOI-03, da mesma forma que a AOI-02, apresentava a ocorrência de Trincas Transversais Longas (TTL), o que para o estudo da metodologia é relevante.

A AOI-06 é a mesma área da AOI-02 que foi adquirida em outra configuração do sensor com resolução espacial 50 cm e 24 bandas espectrais.

A AOI-08 foi escolhida por ser uma área urbana o que permitiu avaliar o comportamento da metodologia nestes casos onde a heterogeneidade da cena é maior.

5.2 Avaliação da qualidade das imagens

Durante o processamento e análise foram verificadas as seguintes anomalias nas imagens:

- Sensor descalibrado;
- Ruído eletrônico;
- Ausência de linhas (*Line Drop*);
- Linhas atenuadas;
- Saturação.

Segundo Clark et al. (2003), a curva espectral característica do asfalto é uma curva semelhante àquela ilustrada na Figura 37. Outra referência do padrão de comportamento do asfalto é o da biblioteca espectral do NCRST ilustrado na Figura 42. O comportamento observado para o asfalto nas amostras retiradas das imagens da pesquisa (Figura 22, Figura 23, Figura 24 e Figura 25) é diferente dos padrões

observados na literatura. A Figura 44 ilustra as curvas espectrais retiradas das imagens em estudo.

Essa diferença se explica inicialmente pelo fato das curvas das imagens estarem em valores de radiância. As imagens sofreram somente a correção radiométrica para transformar os valores digitais (DN) em radiância. Consequentemente, não sofreram nenhuma correção atmosférica para transformar os valores de radiância em valores de reflectância. A Figura 37 e Figura 42 mostram curvas em valores de reflectância, enquanto a Figura 44 mostra curvas em valores de radiância.

Figura 37 – Curva espectral padrão asfalto (CLARK et al., 2003).

Todas as imagens apresentam uma forte atenuação do sinal na faixa do espectro infravermelho próximo, em torno da frequência de 948 nm, conforme pode ser verificado na Figura 9 e na Figura 44. Este efeito é função da absorção da energia por vapor d'água. A Figura 38 mostra o gráfico de transmitância da atmosfera terrestre, onde pode ser observado o efeito de atenuação em torno de 940 nm. A região do espectro em torno de 940 nm é utilizada para o cálculo da coluna de vapor da atmosfera terrestre (CARRERE, 1993).

Outro comportamento observado nas imagens foi a presença de ruído eletrônico na metade direita da faixa imageada. A Figura 39b ilustra o ruído eletrônico nas imagens. Esta anomalia está ligada à eletrônica do sensor, ou a alguma obstrução na fenda da aeronave diminuindo a entrada de luz necessária

para a captura da imagem, assim diminuindo a relação sinal ruído do sensor. Esta anomalia deixa a imagem ligeiramente fora de foco. Para a observação e comprovação desta anomalia foi realizada a Análise de Componente Principal. A última componente principal revela claramente a quantidade de ruído na imagem conforme ilustrada na Figura 39b.

Figura 38 – Detalhe da absorção de energia em 940nm. Curva de transmitância da atmosfera padrão. Adaptado de Clark (1999).

(a)

(b)

Figura 39 – (a) Imagem original e (b) PC8 – oitava componente do resultado da Análise de Componentes Principais

Com baixa ocorrência, outro comportamento observado nas imagens foi a ausência de linhas (*drop line*) conforme ilustrado na Figura 39a. Estas ausências podem ter sido geradas pela correção geométrica do sistema de pós processamento do sensor, em função da atitude da aeronave no momento da aquisição destas linhas, ou por uma falha de aquisição do sistema eletrônico de captura e armazenamento.

Todas as imagens estavam com linhas longitudinais aparentando uma menor amplificação para os elementos da matriz de detecção que compõem esta linha. A Figura 40 ilustra este comportamento.

Por último, com baixa ocorrência também, algumas regiões das imagens apresentaram saturação. A Figura 41 ilustra este comportamento que pode ter ocorrido em função do horário do voo de levantamento, realizado entre 12:00 h e 12:30 h, e pelo ganho de amplificação configurado no sensor.

Figura 40 – Exemplo de linha atenuada encontrada nas imagens.

Figura 41 – Exemplo de uma região saturada.

5.3 Biblioteca espectral

Dentro da metodologia, a biblioteca espectral representa um elemento importante de todo o processo de classificação. A decisão inicial pela utilização de uma biblioteca espectral dentro da metodologia teve como propósito a possibilidade de não necessitar, em cada classificação, realizar a coleta de amostras de treinamento nas imagens que seriam processadas. Desta forma, no futuro, poderia ser feita uma automação das etapas de processamento da metodologia.

Outro fator determinante para o uso da biblioteca espectral foi o método de classificação escolhido para a metodologia que foi o Spectral Angle Mapper (SAM). Para a aplicação da classificação SAM é necessária que as referências espectrais dos materiais em análise estejam disponíveis. Estas referências espectrais são materializadas nas curvas espectrais da biblioteca espectral.

Figura 42 – Curvas espectrais de rodovias da biblioteca NCRST (HEROLD et al.).

O National Center for Remote Sensing in Transportation (NCRST) na Universidade da Califórnia de Santa Bárbara desenvolveu uma biblioteca espectral de materiais urbanos que possui inúmeras amostras de rodovias próximas à cidade de Santa Bárbara, Califórnia, USA.

Segundo Herold et al., a biblioteca espectral possui 26 tipos de coberturas do solo e contém 956 amostras espectrais individuais, foi adquirida utilizando-se um dispositivo ASD (Analytical Spectral Device), que é um espectrômetro de faixa completa. As faixas das amostras são de 350-2500 nm com intervalos de aproximadamente 2 nm.

Essa biblioteca foi cedida pelo NCRST ao Laboratório de Geo Processamento do Departamento de Transporte da EPUSP.

No início da pesquisa aventou-se a possibilidade de uso ou adaptação da biblioteca espectral do NCRST nas imagens disponibilizadas para este trabalho. No entanto, em função de algumas dificuldades já conhecidas de antemão, como a diferença dos materiais que compõem o pavimento das rodovias americanas em relação aos materiais das rodovias brasileiras e fundamentalmente pelas imagens não estarem com correções radiométricas e nem correção atmosférica inviabilizaram a utilização da biblioteca do NCRST.

Diante da impossibilidade de utilização da biblioteca do NCRST e da impossibilidade de criação de uma biblioteca de referência utilizando um espectrômetro, foi criada uma biblioteca espectral a partir das próprias imagens coletadas, ou seja, foram selecionadas amostras de diferentes tipos de asfalto para a criação das curvas espectrais.

Figura 43 – Amostras de asfalto para composição da biblioteca espectral. (a) asfalto claro sem tráfego, (b) e (c) asfalto claro alça de acesso, (d) asfalto claro rodovia, (e) faixa rodagem externa rodovia, (f) faixa de rodagem interna rodovia, (g) remendos, (h) asfalto recapeado.

As amostras retiradas da imagem são dos pontos centrais das imagens da Figura 43 representados pela cruz vermelha. Com estas amostras foi criada a biblioteca espectral da Figura 44.

Figura 44 – Curvas espectrais das amostras de asfaltos da Figura 43

5.4 Pesquisa de Campo

Com objetivo de confirmar em campo as ocorrências de alguns problemas identificados nas imagens, tais como remendos e trincas transversais longas, foi realizada uma pesquisa de campo no dia 11 de Abril de 2010 nos locais das áreas de interesse. A pesquisa de campo foi realizada aproximadamente 1 mês após o voo de aquisição das imagens, de tal forma que as cenas ainda não tinham sofrido alterações significativas.

Figura 45 – (a) AOI-01 e pontos de coleta das imagens; (b), (c) e (d) imagens da pesquisa de campo.

A imagem da Figura 45a mostra alguns remendos que foram confirmados em campo (Figura 45c e Figura 45d). A imagem Figura 45a mostra também duas manchas próximas do ponto b que com a imagem em laboratório não foi possível a identificação do que se tratava. Na visita em campo foi verificado que se tratava de terra espalhada sobre o asfalto e a mancha branca era resto de massa de cimento utilizada em construção (Figura 45b).

Figura 46 – (a) AOI-02 e pontos de coleta das imagens; (b), (c) e (d) imagens da pesquisa de campo.

Antes da campanha de levantamento em campo, as panelas ou buracos mostrados nas Figura 47c e Figura 47d não haviam sido detectados. Acreditava-se que a qualidade do asfalto na região era ótima e que não havia buracos nestas cenas. A partir dos dados coletados em campo foi possível localizar visualmente nas imagens as ocorrências dos buracos encontrados no asfalto. A dimensão dos buracos das Figura 47c e Figura 47d é de aproximadamente 50 cm de diâmetro. Na imagem com melhor resolução espacial (25 cm), o buraco equivale aproximadamente a 4 pixels, inviabilizando praticamente a detecção pelos algoritmos de classificação. Não foi observada durante a pesquisa de campo nenhuma outra ocorrência de um buraco com dimensão maior daqueles fotografados e que poderiam permitir o exercício da metodologia.

Figura 47 – (a) AOI-02 e pontos de coleta das imagens; (b), (c) e (d) imagens da pesquisa de campo.

A Figura 46 mostra uma alça de saída da rodovia Raposo Tavares. Pela análise visual das imagens desta região, realizada antes da pesquisa de campo, foi possível identificar somente os remendos no asfalto. No entanto, durante a pesquisa de campo além dos remendos foram observadas trincas interligadas semelhantes às trincas em forma de couro de jacaré sem erosão, conforme mostrado na Figura 46c.

Figura 48 – (a) AOI-04 e pontos de coleta das imagens; (b), (c), (d), (e) e (f) imagens da pesquisa de campo.

Da análise visual preliminar das imagens em laboratório, um conjunto de trincas transversais longas foi verificado nas imagens, Figura 48a. No entanto durante a pesquisa de campo constatou-se que a maioria destas trincas transversais longas foram seladas com material impermeabilizante preto, Figura 48 b, c e d. O material selante aumentou o contraste e a área aparente das trincas, destacando-as nas imagens capturadas. Somente um pequeno trecho de estrada interrompido e sem rodagem estava com trincas transversais longas que ainda não haviam recebido o selante, Figura 48 e e f.

Figura 49 – (a) AOI-02 e pontos de coleta das imagens; (b), (c), (d), (e) e (f) imagens da pesquisa de campo.

A Figura 49 desta os remendos e trincas seladas encontradas durante a pesquisa de campo na AOI-01. As trincas da Figura 49f não são visíveis na imagem espectral, pois coincidem com áreas saturadas da imagem. A Figura 49b, além dos remendos, destaca ainda a ciclovia que na imagem espectral aparece como uma faixa laranja no canto da imagem.

5.5 Resultados do Processo Detectar Asfalto

A primeira etapa da metodologia, Detectar Asfalto, foi aplicada às áreas de interesse 01, 02, 03, 06 e 08. As áreas compõem um conjunto de amostras representativas das imagens originais. A AOI-1 é uma imagem da rodovia inserida dentro do cenário urbano da cidade de Sorocaba. A AOI-02 é uma amostra da rodovia cercada principalmente por vegetação e rio aproximando-se de um cenário rural que seria encontrado caso as imagens fossem adquiridas em outra região. A comparação da AOI-02 a um cenário rural é uma comparação simplista, há um número enorme de possibilidades de composição do cenário rural com a rodovia. Por exemplo: rodovia próxima a solo exposto, a água, aos diversos tipos de vegetação (pasto, grama, floresta ou cerrado), etc. No entanto, devido a ausência de outras imagens para pesquisa, principalmente de uma área rural, a AOI-02 serve como uma aproximação de uma rodovia cortando a área rural.

A AOI-06 foi processada como amostra da imagem com resolução espacial de 50 cm e 24 bandas.

A AOI-08 também foi processada como amostra de uma área urbana. Neste caso, é uma cena bastante representativa de uma área urbana com ocupação regular, predominantemente por construções em alvenaria e telhado cerâmico. Há uma parcela significativa com vegetação e também de solo exposto, semelhante a terrenos não ocupados.

Com objetivo de avaliar o resultado de cada passo do processamento da primeira etapa da metodologia, foram construídas manualmente e visualmente imagens de verdade de campo para as AOI mencionadas. Com as imagens de verdade de campo foi possível calcular a matriz de confusão do resultado de cada passo do processamento e assim avaliar se os passos da metodologia estavam contribuindo ou não para a melhoria da imagem classificada como asfalto.

5.5.1 Avaliação dos filtros espaciais

Após o término da classificação inicial utilizando o classificador SAM, a metodologia prevê o uso de filtros espaciais para a melhoria do resultado da

classificação. Em função da natureza do problema, quatro filtros foram escolhidos inicialmente para serem avaliados na metodologia: filtro de Sieve, filtro de Clump, filtro de convolução da média e filtro de convolução passa baixa. Clump tem como objetivo agrupar áreas similares que são adjacentes. O Sieve tem como objetivo retirar grupos de pixels isolados, ou seja, para o caso do asfalto, grupos de pixels isolados possivelmente não representam asfalto, mas sim alguma confusão com outra classe similar ao asfalto. O filtro de convolução da média tende a suavizar a imagem, principalmente as bordas dos objetos, também ajuda a remover a ocorrência de pixels isolados. O filtro de convolução passa baixa permite somente a passagem das frequências baixas, tem efeito semelhante ao filtro da média, no entanto, o efeito é mais acentuado. As bordas dos objetos tem uma suavização maior.

A ordem em que os filtros são aplicados influencia no resultado final da imagem. Para analisar a ordem e o efeito produzido pelos filtros, o seguinte experimento em forma de árvore de decisão foi realizado, Figura 50. Em cada nó da árvore de decisão foi calculada a matriz de confusão para medir o quanto cada filtro estava contribuindo para a classificação da imagem do asfalto. Este experimento foi realizado somente para a AOI-01.

Figura 50 – Experimento Árvore de decisão – Filtros espaciais.

A Tabela 12 apresenta o resultado da matriz de confusão de cada nó da árvore de decisão da Figura 50. Apresenta o índice de exatidão geral, o índice Kappa, os percentuais de comissão e omissão das classes asfalto e não asfalto.

Analisando a Tabela 12, os nós que apresentaram melhor índice de exatidão geral foram os nós 10 e 12. Os nós 10 e 12 chegaram ao mesmo resultado final, ou seja, a sequência Classificação SAM (1), Filtro Clump (8), Filtro Sieve (9) e Filtro da Média (10) produziu o mesmo resultado da sequência Classificação SAM (1), Filtro Clump (8) e Filtro da Média (12). Isto mostra que para estas duas sequências, o filtro de Sieve não contribui para o resultado final da classificação. A sequência de execução que termina no nó 12 tem a vantagem de economizar um passo de processamento dos filtros, ou seja, é mais eficiente e possui um esforço computacional menor.

Tabela 12 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para os nós da árvore de decisão da Figura 50.

Nó	Exatidão	Kappa	Asfalto		Não Asfalto	
			Comissão	Omissão	Comissão	Omissão
1	91,22	0,67	19,25	34,88	7,07	3,27
2	91,24	0,67	18,94	35,13	7,11	3,20
3	92,03	0,72	21,45	25,37	5,30	4,30
4	92,44	0,73	19,72	24,99	5,20	3,89
5	92,31	0,74	23,00	20,36	4,33	5,02
6	91,49	0,67	16,67	36,09	7,26	2,70
7	92,11	0,72	20,46	26,28	5,46	4,00
8	92,06	0,72	22,00	24,18	5,07	4,51
9	92,08	0,72	21,90	24,21	5,04	4,48
10	92,52	0,73	20,17	23,66	4,95	4,07
11	92,32	0,74	23,53	19,21	4,10	5,24
12	92,52	0,73	20,17	23,66	4,95	4,07
13	92,32	0,74	23,54	19,20	4,10	5,25
14	91,50	0,67	16,73	35,95	7,23	2,71
15	92,14	0,72	20,56	25,94	5,40	4,04

No entanto, para o nó 12 o erro por comissão da classe Asfalto aumenta em relação à classificação original, nó 1, sobe de 19,25% para 20,17%, mas erro por omissão diminui numa proporção muito maior de 34,88% para 23,66%.

A partir dos resultados apresentados na Tabela 12, a sequência para execução dos filtros espaciais foi definida como sendo a sequência de execução que termina no nó 12, ou seja, depois da classificação SAM, somente os filtros de Clump e da Média são aplicados nesta ordem.

5.5.2 Resultados após a classificação por objetos

Após o estabelecimento dos filtros espaciais e da sequência em que seriam aplicados às imagens, todas as AOI foram processadas.

O próximo passo da metodologia é a classificação baseada em objetos do resultado da classificação por pixel do classificador SAM corrigida pelos filtros espaciais. Este passo da metodologia visa também aumentar a exatidão na classificação do asfalto das imagens iniciais.

As imagens foram importadas na ferramenta e-Cognition e processadas segundo as regras definidas na metodologia. O resultado foi exportado de volta para o software Envi onde foi feita outra comparação com a imagem verdade de campo para gerar a matriz de confusão. Esta última matriz foi identificada como sendo o nó 16 da árvore de decisão.

As tabelas 9, 10, 11, 12 e 13 apresentam os resultados do processamento das AOI 01, 02, 03, 06 e 08 respectivamente.

Tabela 13 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-01.

AOI 01			Asfalto		Não Asfalto	
Nó	Exatidão	Kappa	Comissão(%)	Omissão(%)	Comissão(%)	Omissão(%)
1	91,22	0,67	19,25	34,88	7,07	3,27
8	92,06	0,72	22,00	24,18	5,07	4,51
12	92,51	0,73	20,17	23,66	4,95	4,07
16	93,06	0,75	16,90	24,46	5,06	3,24

Tabela 14 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-02.

AOI 02			Asfalto		Não Asfalto	
Nó	Exatidão	Kappa	Comissão(%)	Omissão(%)	Comissão(%)	Omissão(%)
1	95,03	0,77	16,57	23,64	3,22	2,09
8	94,87	0,76	22,51	18,76	2,60	3,25
12	94,92	0,77	22,29	18,58	2,58	3,22
16	94,94	0,77	22,13	18,56	2,57	3,19

Tabela 15 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-03.

AOI 03			Asfalto		Não Asfalto	
Nó	Exatidão	Kappa	Comissão(%)	Omissão(%)	Comissão(%)	Omissão(%)
1	86,83	0,53	31,70	45,45	9,93	5,79
8	87,20	0,56	33,09	38,21	8,59	6,99
12	87,40	0,57	32,25	38,38	8,60	6,70
16	87,84	0,58	30,14	39,05	8,67	6,01

Tabela 16 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-06.

AOI 06			Asfalto		Não Asfalto	
Nó	Exatidão	Kappa	Comissão(%)	Omissão(%)	Comissão(%)	Omissão(%)
1	91,98	0,68	26,66	27,38	4,79	4,63
8	93,04	0,74	27,33	14,49	2,62	5,64
12	93,42	0,76	25,93	14,05	2,53	5,27
16	93,93	0,77	22,90	15,66	2,79	4,39

Tabela 17 – Índices de Exatidão Geral, Kappa, Comissão e Omissão das classes Asfalto e Não Asfalto para AOI-08.

AOI 08			Asfalto		Não Asfalto	
Nó	Exatidão	Kappa	Comissão(%)	Omissão(%)	Comissão(%)	Omissão(%)
1	87,70	0,56	45,50	23,50	4,12	10,47
8	86,90	0,56	47,80	17,02	3,09	12,45
12	88,07	0,59	44,95	16,50	2,95	11,18
16	90,13	0,64	38,93	17,32	3,01	8,64

Para a AOI-02, os filtros espaciais pioraram a classificação inicial realizada pelo SAM. A AOI-02 é uma cena mais homogênea, conforme descrito anteriormente, representativa de um cenário rural. Neste caso, a discriminação feita pelo classificador SAM na imagem espectral foi suficiente para separar o asfalto das outras classes.

Para as outras AOI, os filtros aplicados e também a classificação por objetos melhoram o resultado inicial obtido pela classificação SAM.

A Tabela 18 sintetiza o resultado final do processo de detecção do asfalto para as AOI pesquisadas. A coluna Exatidão (1) é a exatidão após a classificação pixel a pixel utilizando SAM e a coluna Exatidão (16) é a exatidão final da imagem após a execução dos filtros espaciais e também da classificação baseada em objetos.

Tabela 18 – Avaliação da aplicação dos filtros espaciais e da classificação por objetos às AOI.

	Exatidão (1)	Exatidão (16)	Diferença	%
AOI 01	91,22	93,06	1,84	2,0%
AOI 02	95,03	94,94	-0,09	-0,1%
AOI 03	86,83	87,84	1,01	1,2%
AOI 06	91,98	93,93	1,95	2,1%
AOI 08	87,70	90,13	2,43	2,8%

O último passo do processo Detectar Asfalto é a criação da imagem que será a máscara utilizada para recortar a imagem espectral inicial e produzir uma imagem espectral contendo somente informação de asfalto, observando-se os erros de comissão e omissão registrados anteriormente.

Tabela 19 – Sequência de passos e seus resultados para o processo Detectar Asfalto.

Passo	Resultado
Imagem espectral inicial da AOI-01.
Passo 1: Classificação SAM utilizando a biblioteca espectral.
Passo 1a: As classes dos diferentes tipos de asfalto foram combinadas em um só classe.

<p>Passo 2:</p> <p>Aplicação do filtro de Clump.</p>
<p>Passo 3:</p> <p>Aplicação do filtro de convolução da média.</p>
<p>Passo 4a:</p> <p>Segmentação da imagem no eCognition.</p>
<p>Passo 4b:</p> <p>Classificação da imagem no eCognition:</p> <p>Asfalto, Ilhas de asfalto (vermelho) e Não Asfalto.</p>
<p>Passo 4c:</p> <p>Somente a classe Asfalto da classificação baseada em objetos.</p>

<p>Passo 5:</p> <p>Geração da imagem binária que será utilizada como máscara.</p>	<p>The image shows an aerial view of a road network. A binary mask is overlaid on the image, highlighting the road features in white against a black background. The mask is used for image processing purposes.</p>
<p>Passo 6:</p> <p>Imagem espectral recortada contendo somente asfalto.</p>	<p>The image shows an aerial view of a road network. A binary mask is overlaid on the image, highlighting the road features in white against a black background. The mask is used for image processing purposes.</p>

5.6 Resultados do Processo de Classificação dos Defeitos do Asfalto

A região de Sorocaba, onde o voo de levantamento foi realizado, é uma região política e economicamente muito forte quando comparada com outras regiões brasileiras, o que contribui diretamente para que as estradas, os acessos e as ruas da região sejam bem conservados. A região é também atravessada por uma das principais rodovias do país, a Raposo Tavares, SP-270. Desta forma, as imagens capturadas na região não trazem um conjunto de amostras expressivas e que sejam representativas das ocorrências dos possíveis defeitos dos pavimentos asfálticos.

Os principais defeitos com potencial de serem detectados nas imagens disponíveis para a pesquisa foram os remendos, os buracos, as trincas longas longitudinais / transversais e as trincas em bloco ou forma de couro de jacaré.

A segunda etapa da metodologia, Processo de Classificação dos Defeitos do Asfalto, é muito mais susceptível à qualidade das amostras (ruídos, distorções, resolução, etc) do que a primeira etapa de Detecção do Asfalto, pois a dimensão dos objetos de interesse são, na maioria, menores do que a resolução espacial das imagens disponíveis.

5.6.1 Processamento dos Remendos

Os remendos são os defeitos com o maior número de ocorrências nas imagens disponíveis e também são os de maior visibilidade em função do tamanho dos objetos versus a resolução das imagens.

Para os remendos do asfalto, utilizando-se imagens de resolução espacial de 25 cm e resolução espectral de 8 bandas, os melhores parâmetros de segmentação foram, escala 150, forma 0,3 e compacidade de 0,5. A Figura 51 ilustra a tela do programa eCognition com os respectivos valores de segmentação ajustados.

Figura 51 – Tela do programa eCognition com os parâmetros de segmentação da imagens para classificação dos remendos.

Para classificação dos remendos do asfalto nas imagens pesquisadas foi construída uma classe que considera tanto os aspectos espectrais quanto os aspectos de forma dos objetos. Os seguintes atributos de forma foram utilizados na classe remendo: Índice de borda (*Border Index*), Relação Comprimento Largura (*Lenght/Width*), Ajuste Retangular (*Retangular Fit*) e o Índice de Forma (*Shape Index*).

O Índice de borda é calculado como sendo a razão entre o comprimento da borda do objeto da imagem e o comprimento da borda do menor retângulo

envolvente, Figura 52a. O índice varia 1 a infinito, quanto mais o objeto é parecido com um fractal maior será o índice de borda.

Ajuste Retangular mede o quanto o objeto da imagem está próximo de um retângulo de mesma área, Figura 52b. Varia de 0 a 1, quanto mais próximo de 1 mais o objeto se ajusta a um retângulo.

Índice de Forma é o comprimento da borda dividido por 4 vezes a raiz quadrada da área do objeto. O índice varia 1 a infinito, da mesma forma que o Índice de Borda, quanto mais o objeto é parecido com um fractal maior será o índice de forma. O Índice de Forma indica o quanto a borda de um objeto é lisa ou não.

Figura 52 – (a) Ilustração do conceito de Índice de Borda. (b) Ilustração do conceito do Índice de Forma utilizados pelo software eCognition.

Da maneira que a classe Remendo foi construída, os índices de borda, forma e ajuste retangular privilegiam a forma retangular para os remendos. Remendos com forma arredondada não terão pontuação elevada durante a classificação.

Para a construção das funções de pertinência dos atributos da classe, foram coletadas amostras de objetos remendo na própria imagem. Os valores das amostras para os atributos que compõem a classe remendo, descritos acima, serviram para dimensionar o intervalo de confiança das funções de pertinência. Os valores do Ajuste Retangular das amostras coletadas tinham uma distribuição bimodal. Para atender esta distribuição foram criadas duas funções de pertinência para o Ajuste Retangular que se somam através de uma operação “OU” na definição da classe Remendo, Figura 53. Estando o espaço de atributos definido para a classe e as amostras selecionadas, a ferramenta gera automaticamente as funções de pertinência conforme ilustrado na Figura 53b.

Figura 53 – (a) Descrição da classe Remendo em termos das funções de pertinência. (b) Histograma dos atributos utilizados nas funções de pertinência da classe Remendo.

As Figura 54 ilustra um recorte da imagem AOI-01 onde há a ocorrência de diversos remendos e a Figura 55 ilustra em destaque (vermelho) os remendos que foram classificados. Como em qualquer algoritmo de classificação, existem remendos que não foram classificados (erro de omissão) e outros que foram classificados como sendo remendos e que não são (erro de comissão).

No entanto, a classe Remendo teve um desempenho ruim como classificador para detectar remendos de asfalto nas imagens. A Tabela 20 mostra os resultados da classificação para as quatro áreas de interesse e também para a imagem 03 completa. O erro médio de Comissão foi 55,5% e o erro médio de

Omissão foi de 54%. A contabilização da eficácia da classificação foi feita comparando visualmente a imagem classificada com a imagem original.

A Tabela 20 mostra a quantidade de objetos classificados como remendo, a quantidade de objetos classificados como asfalto, a área dos objetos classificados como remendo, a área dos objetos classificados como asfalto, a porcentagem dos objetos remendo em relação aos objetos asfalto, a porcentagem da área dos objetos remendo em relação à área dos objetos asfalto, mostra os parâmetros de segmentação utilizados em cada cena e, por fim, mostra os erros de comissão e omissão.

Tabela 20 – Resultado da classificação baseada em objetos para identificação de remendos.

AOI	Nro Objetos		Área (m2)		% Obj.	% Área	Segmentação			Comissão	Omissão
	Remendo	Asfalto	Remendo	Asfalto			Escala	Forma	Compa- cidade		
AOI-01	102	2.817	1.163,56	60.267,31	3,6%	1,9%	150	0,3	0,5	49,0%	44,7%
AOI-02	20	727	209,25	13.946,50	2,8%	1,5%	150	0,3	0,5	55,0%	47,1%
AOI-03	12	906	97,40	22.034,00	1,3%	0,4%	150	0,3	0,5	33,3%	52,9%
AOI-04	13	928	103,31	20.991,81	1,4%	0,5%	150	0,3	0,5	84,6%	71,4%
Imagem 03	480	17.688	4.416,56	385.856,50	2,7%	1,1%	150	0,3	0,5

Figura 54 – Recorte da AOI-01 ilustrando os remendos no asfalto.

Figura 55 – Em destaque (vermelho) os remendos identificados na classificação baseada em objetos

5.6.2 Processamento das Trincas Longas

Da inspeção e análise visual das imagens somente um conjunto de trincas transversais longas foram verificadas nas imagens. Durante a pesquisa de campo constatou-se que a maioria destas trincas transversais longas estavam seladas com material impermeabilizante preto. O material selante aumentou o contraste e a área aparente das trincas, destacando-as nas imagens capturadas, conforme mostra a Figura 48. Somente um pequeno trecho de estrada interrompido e sem rodagem estava com trincas transversais longas que ainda não haviam recebido o selante. As imagens das Figura 48a, Figura 48e e Figura 48f mostram este pequeno trecho de estrada e as trincas expostas. As trincas apresentam erosão e possuem abertura de aproximadamente 1,5 cm e comprimento de 2 m.

Na ausência de outras imagens com resolução espacial melhor e com mais informações e amostras de outros tipos de trincas, as imagens disponíveis foram processadas e trabalhadas buscando-se o aprimoramento da metodologia e o entendimento do comportamento dos objetos que ilustram esta classe.

Por serem alvos menores do que a resolução espacial das imagens, as trincas possuem um comportamento muito peculiar quando comparado a outros objetos da cena, mesmo considerando as trincas que foram alargadas pelo selante. A segmentação da imagem com objetivo de separar as trincas é de difícil obtenção, pois os objetos ficam muito pequenos e de difícil manipulação. Para tanto, foi realizado um pequeno experimento com os parâmetros do segmentador (escala, forma e compacidade) tendo como objetivo encontrar os melhores parâmetros para segmentar os objetos que representassem as trincas. Inicialmente foi fixada a escala e realizada a variação das variáveis de forma e compacidade. Depois de encontrada uma relação suficiente de forma e compacidade foi alterada o parâmetro de escala, conforme mostrado na Tabela 21.

Tabela 21 – Estudo dos parâmetros de segmentação para a classe trincas longas.

Escala / Forma	Compacidade		
Escala 20	0.1	0.5	0.9
0.1
0.5
0.7
0.8
0.9

Para esta parte da imagem que foi estudada, a escala 20 com parâmetros de forma igual a 0,7 e compacidade de 0,9 apresentou o melhor resultado, do segmentador. Os objetos são maiores e a maioria das trincas mantiveram-se um único objeto.

Em outras escalas, Tabela 22, o melhor comportamento dos objetos para as trincas longas foi a escala 50 com forma igual a 0,1 e compacidade de 0,9.

Tabela 22 – Estudo dos parâmetros de segmentação para a classe trincas longas (Cont.).

Escala / Forma	Compacidade		
Escala 30			0.9
0.1
0.5
0.7
Escala 40			0.9
0.1
Escala 50			0.9
0.1
Escala 60	0.7	0.8	0.9
0.1

A classe TrincaLonga foi definida a partir dos seguintes atributos: Área, relação Comprimento Largura, Índice de Forma e os valores espectrais. A classe foi

construída tendo como base o comportamento delgado dos objetos o que justifica a utilização da relação Comprimento Largura e do Índice de Forma e também por apresentar em tese área de valores pequenos.

Para a construção das funções de pertinência dos atributos selecionados para classe TrincaLonga foram utilizadas amostras de trincas da AOI-03. Mesmo não sendo trincas verdadeiras, as amostras selecionadas foram as trincas com selante, pois apresentam uma maior chance de serem identificadas nas imagens.

Com o conjunto de amostras selecionadas, o software eCognition gera automaticamente as curvas de pertinência que podem ser vistas na Figura 56b. A Figura 56a mostra a composição da classe TrincaLonga.

Figura 56 – (a) Descrição da classe TrincaLonga em termos das funções de pertinência. (b) Histograma dos atributos utilizados nas funções de pertinência da classe TrincaLonga.

Figura 57 – Em destaque (vermelho) as trincas identificadas na classificação baseada em objetos. Segmentação escala 20, forma 0,7 e compacidade 0,9. Recorte da AOI-03.

Figura 58 – Em destaque (vermelho) as trincas identificadas na classificação baseada em objetos. Segmentação escala 20, forma 0,7 e compacidade 0,9. Recorte da AOI-04.

A classificação foi aplicada nas áreas de interesse e também em outro recorte de cena em que apareciam algumas trincas longas seladas. A classificação foi realizada nas duas melhores segmentações definidas pelo estudo de segmentação das trincas.

A Tabela 23 mostra o resultado da classificação das trincas em cada cena para as duas segmentações. A tabela mostra a quantidade de objetos classificados como trinca, a quantidade de objetos classificados como asfalto, a área dos objetos classificados como trinca, a área dos objetos classificados como asfalto, a porcentagem dos objetos trinca em relação aos objetos asfalto, a porcentagem da área dos objetos trinca em relação à área dos objetos asfalto e, por fim, mostra os parâmetros de segmentação utilizados em cada cena.

Por não haver um método automatizado para verificação dos erros de comissão e omissão das classificações, estes não foram levantados. No entanto, o resultado qualitativo da classificação foi pior que a classificação dos remendos. As imagens da Figura 57 e da Figura 58 mostram o resultado da classificação das trincas em vermelho. Quando a imagem foi alterada para outra imagem diferente daquela onde foram colhidas as amostras de treinamento, o classificador não identificou as trincas existentes na imagem, veja Figura 58. Neste caso, os parâmetros de segmentação estudados para as trincas da Figura 57 não tiveram o mesmo desempenho para segmentar as trincas da imagem da Figura 58, assim, prejudicando a classificação das trincas. As faixas de sinalização da pista de rodagem e os objetos próximos foram confundidos com trincas pelo classificador.

Tabela 23 – Resultado da classificação baseada em objetos das AOI para identificação de “trincas” longas.

AOI	Nro Objetos		Área (m ²)		% Obj.	% Área	Segmentação		
	Trinca	Asfalto	Trinca	Asfalto			Escala	Forma	Compa- cidade
AOI-01	264	46.159	352,44	61.038,31	0,6%	0,6%	20	0,7	0,9
AOI-01	109	20.785	136,44	61.254,81	0,5%	0,2%	50	0,1	0,9
AOI-02	99	11.953	126,81	14.019,19	0,8%	0,9%	20	0,7	0,9
AOI-02	53	5.373	66,70	14.079,34	1,0%	0,5%	50	0,1	0,9
AOI-03	129	14.989	175,06	21.948,75	0,9%	0,8%	20	0,7	0,9
AOI-03	54	6.405	70,50	22.053,38	0,8%	0,3%	50	0,1	0,9
AOI-04	117	18.470	146,88	20.945,81	0,6%	0,7%	20	0,7	0,9
AOI-04	47	7.600	59,44	21.032,85	0,6%	0,3%	50	0,1	0,9
Recorte	67	11.717	100,38	13.708,19	0,6%	0,7%	20	0,7	0,9
Recorte	21	5.196	31,69	13.776,88	0,4%	0,2%	50	0,1	0,9

Assim sendo, os valores apresentados na Tabela 23 que foram retirados do resultado da classificação não são valores representativos da quantidade de trincas nas imagens.

5.6.3 Processamento dos Buracos/Panelas

Como as imagens disponíveis para a pesquisa são de uma área com baixa ocorrência de buracos e os únicos buracos identificados durante a pesquisa de campo (Figura 46) não são sistematicamente mensuráveis nas imagens, não foi realizado nenhum processamento e desenvolvimento de classe de objetos para classificar os defeitos Buracos/Panelas.

5.6.4 Análise com as Componentes Principais

Por ser o objeto da pesquisa um estudo de investigação do uso de imagens espectrais com alta resolução espacial na identificação dos defeitos dos pavimentos asfaltados, além da utilização das imagens diretamente na forma que elas foram fornecidas, foram realizados estudos com as componentes principais das imagens das áreas de interesse.

O mesmo princípio de classificação por objeto adotado na classificação das imagens espectrais foi adotado para as componentes principais que são o resultado da transformação de rotação aplicada às imagens espectrais originais.

A transformação para componentes principais foi realizada sobre as imagens resultantes da primeira etapa de processamento de Detectar Asfalto (e.g., Tabela 19, passo 6). Para as imagens representando somente o asfalto, a primeira componente principal reteve quase toda a heterogeneidade das bandas espectrais da imagem original. Dentre as oito componentes principais calculadas, as componentes que mais destacam, tanto para a ocorrências das trincas seladas como para as ocorrências dos remendos no asfalto foram as componentes 1, 2, 3 e 4. A Figura 59 ilustra as componentes principais 1, 2, 3 e 4 de um recorte da imagem AOI-01 com a ocorrência de remendos. A Figura 60 ilustra as componentes

principais 1, 2, 3 e 4 de uma saída da rodovia Raposo Tavares com a ocorrência de trincas longas seladas.

Figura 59 – Recorte da imagem da AOI-01 contendo remendos. (a) Primeira componente principal. (b) Segunda componente principal. (c) Terceira componente principal. (d) Quarta componente principal.

Para realização da segmentação das imagens tanto para a classificação dos buracos como para a classificação das trincas longas foram utilizadas somente as componentes principais 1, 2, 3, e 4. As outras componentes (5, 6, 7 e 8) não apresentaram nenhuma informação de trincas e nem de buracos. Os parâmetros de

escala, forma e compacidade também foram mantidos na segmentação das imagens das componentes principais. A Figura 61 ilustra a segmentação realizada nas imagens de componentes principais 1, 2, 3 e 4 da AOI-03.

Figura 60 – Recorte da imagem da AOI-04 contendo “trincas longas” seladas. (a) Primeira componente principal. (b) Segunda componente principal. (c) Terceira componente principal. (d) Quarta componente principal.

Para execução da classificação sobre as imagens das componentes principais, as classes Remendo e TrincaLonga foram modificadas para considerarem somente as componentes 1, 2, 3 e 4. Como houve uma nova segmentação e, consequentemente, os objetos de imagens são diferentes dos objetos da

segmentação anterior realizada sobre as imagens espectrais, foi preciso também reconstruir as funções de pertinência dos atributos das classes. Para reconstruir as funções foi preciso selecionar novas amostras de remendo e também de trincas para treinar os classificadores respectivamente. Sempre que possível, foram selecionadas amostras dos mesmos remendos e das mesmas trincas utilizadas nas classificações anteriores, minimizando o viés de seleção das amostras.

Figura 61 – Recorte da segmentação da AOI-03 sobre as imagens das componentes principais 1, 2, 3 e 4. (a) Segmentação com escala 20, forma 0,7 e compacidade 0,9. (b) Segmentação com escala 50, forma 0,1 e compacidade 0,9.

A Tabela 24 mostra a quantidade de objetos classificados como remendo nas imagens das componentes principais 1, 2, 3 e 4, a quantidade de objetos classificados como asfalto, a área dos objetos classificados como remendo, a área dos objetos classificados como asfalto, a porcentagem dos objetos remendo em relação aos objetos asfalto, a porcentagem da área dos objetos remendo em relação à área dos objetos asfalto, os parâmetros de segmentação utilizados em cada cena e, por fim, mostra os erros de comissão e omissão.

Tabela 24 – Resultado da classificação baseada em objetos das AOI transformadas em componentes principais para identificação de remendos.

AOI	Nro Objetos		Área (m2)		% Obj.	% Área	Segmentação			Comissão	Omissão
	Remendo	Asfalto	Remendo	Asfalto			Escala	Forma	Compacidade		
AOI-01	43	2.817	322,94	61.107,93	1,5%	0,5%	150	0,3	0,5	74,4%	88,3%
AOI-02	3	727	42,56	14.113,19	0,4%	0,3%	150	0,3	0,5	33,3%	88,2%
AOI-03	7	906	43,44	22.087,96	0,8%	0,2%	150	0,3	0,5	85,7%	94,1%
AOI-04	2	928	8,56	21.086,56	0,2%	0,0%	150	0,3	0,5	100,0%	100,0%

A Tabela 25 mostra o resultado da classificação das trincas em cada cena para a segmentação das imagens das componentes principais 1, 2, 3 e 4 com parâmetros de escala 20, forma 0,7 e compacidade 0,9. A tabela mostra a quantidade de objetos classificados como trinca, a quantidade de objetos classificados como asfalto, a área dos objetos classificados como trinca, a área dos objetos classificados como asfalto, a porcentagem dos objetos trinca em relação aos objetos asfalto, a porcentagem da área dos objetos trinca em relação à área dos objetos asfalto e, por fim, mostra os parâmetros de segmentação utilizados em cada cena.

Tabela 25 – Resultado da classificação baseada em objetos das AOI transformadas em componentes principais para identificação de “trincas” longas.

AOI	Nro Objetos		Área (m2)		% Obj.	% Área	Segmentação		
	Trinca	Asfalto	Trinca	Asfalto			Escala	Forma	Compacidade
AOI-01	136	46.159	300,50	61.090,25	0,3%	0,5%	20	0,7	0,9
AOI-02	40	11.953	103,19	14.042,81	0,3%	0,7%	20	0,7	0,9
AOI-03	86	14.989	218,25	21.905,56	0,6%	1,0%	20	0,7	0,9
AOI-04	103	18.470	219,50	20.873,19	0,6%	1,1%	20	0,7	0,9
Recorte	16	11.717	38,06	13.708,19	0,1%	0,3%	20	0,7	0,9

5.6.5 Geração dos Índices de Defeitos do Asfalto

O último passo do processamento da Classificação dos Defeitos do Asfalto é geração dos índices por defeito encontrados nas imagens e consequentemente a geração do Índice Gravidade Global por imagem – IGG’ ou do Índice Gravidade Global Exedito por imagem – IGGE’.

No entanto, como a extração das informações dos defeitos realizada nos passos anteriores não gerou informações consistentes para a resolução espacial das imagens utilizadas. O cálculo dos índices por categoria e o IGG’/IGGE’ foram prejudicados.

Somente para exemplificar o método para geração dos índices, os valores encontrados nos passos anteriores de processamento serão utilizados.

Adotando-se a Equação 6 da página 70 para o cálculo do índice relativo de ocorrência dos defeitos do asfalto e transcrita a seguir, temos que para cada imagem das AOI, o índice para o defeito remendo pode ser extraído diretamente da

coluna “% Área” da Tabela 20, o mesmo para o índice do defeito trincas longas apresentado na Tabela 23.

$$I_{cat} = \frac{\sum area(Ocat)}{\sum area(Oasfalto)}$$

Adotando-se os fatores de ponderação descritos na Tabela 5 para os defeitos do asfalto, a Equação 3 da página 53 para o cálculo do IGI' e a Equação 4 da página 53 para o cálculo do IGG', a tabela a seguir pode ser construída.

Tabela 26 – Cálculo do IGI' e do IGG' a partir das imagens.

	Índice	Índice	Índice	fp	fp	fp	IGI'	IGI'	IGI'	IGG'
AOI	Remendo	Trincas	Buracos	Remendo	Trincas	Buracos	Remendo	Trincas	Buracos	
AOI-01	0,019	0,006	0	0,6	0,2	1	0,012	0,001	0,000	0,013
AOI-02	0,015	0,009	0	0,6	0,2	1	0,009	0,002	0,000	0,011
AOI-03	0,004	0,008	0	0,6	0,2	1	0,003	0,002	0,000	0,004
AOI-04	0,005	0,007	0	0,6	0,2	1	0,003	0,001	0,000	0,004

Assim, é possível construir um Índice Gravidade Global por imagem conforme ilustrado na Tabela 26.

Da mesma forma, adotando-se os fatores de ponderação descritos na Tabela 9 e a Equação 5 da página 56 para o cálculo do IGGE', a tabela a seguir pode ser construída.

Tabela 27 – Cálculo do IGGE' a partir das imagens.

	Índice	Índice	Índice	Ppr	Pt	Ppr	IGGE'
AOI	Remendo	Trincas	Buracos	Remendo	Trincas	Buracos	
AOI-01	0,019	0,006	0	0,7	0,3	0,7	0,015
AOI-02	0,015	0,009	0	0,7	0,3	0,7	0,013
AOI-03	0,004	0,008	0	0,7	0,3	0,7	0,005
AOI-04	0,005	0,007	0	0,7	0,3	0,7	0,006

6 Discussão

A obtenção de imagens com características espectrais e espaciais suficientes para o desenvolvimento da pesquisa foi sempre um desafio a ser vencido. O melhor conjunto de imagens coletado, com amostra significativa de asfalto e com resoluções espacial e espectral mínimas, foi o da região de Sorocaba, São Paulo – SP, realizado em fevereiro de 2010. O sensor hiperespectral utilizado permite a configuração da quantidade de bandas que serão adquiridas em cada faixa de imagem e a resolução espacial é dependente da altura da plataforma durante a aquisição. No entanto, há um compromisso entre o número de bandas selecionadas, resolução espacial e velocidade da plataforma de levantamento. Quanto maior o número de bandas menor deve ser a velocidade da plataforma, pois com o aumento das bandas na imagem, aumenta também a quantidade de dados transferidos da cabeça sensor para unidade de processamento e armazenamento do mesmo. O tempo de integração e armazenamento do sensor deve ser menor do que o tempo para que a próxima linha de aquisição esteja disponível, o que depende também da resolução espacial no sentido do voo (*along track resolution*). Quanto maior o número de informação espectral e resolução espacial em uma imagem é melhor para o desenvolvimento da pesquisa. No entanto, por uma restrição do sistema de aquisição (plataforma e desempenho do sensor) estas duas características são inversamente proporcionais. Diante deste fato, duas configurações foram criadas para o sensor, uma com a máxima resolução espacial possível (25 cm de resolução espacial e 8 bandas espectrais) e a outra, com ênfase nas bandas espectrais, minimizando a perda da resolução espacial (50 cm de resolução espacial e 24 bandas espectrais). Nesta configuração a resolução espacial piorou de 25 cm para 50 cm, mas a resolução espectral aumentou de 8 para 24 bandas espectrais.

Como o voo de aquisição foi um voo de oportunidade, não foi possível determinar uma região onde houvesse um número maior de ocorrências de defeitos do asfalto. A região de Sorocaba é uma região política e economicamente diferenciada em relação a outras regiões do país, o que contribui diretamente para

que as estradas, os acessos e as ruas da região sejam bem conservados. Da mesma forma, a rodovia Raposo Tavares, SP-270, é uma das principais rodovias brasileiras. Consequentemente, em função do poder econômico da região e da importância da rodovia, o estado geral de conservação do asfalto é bom, não gerando nas imagens coletadas um número de amostras significativas dos principais defeitos do asfalto.

A pesquisa de campo foi importante na identificação de problemas que estavam presentes na imagem e que em campo não se mostraram exatamente os mesmos da imagem. As imagens mostravam trincas longas transversais em algumas alças de acesso e de saída da rodovia. No entanto, durante a pesquisa de campo foi constatado que estas trincas estavam mais visíveis nas imagens porque estavam seladas e, com a aplicação do selante, a área da trinca ficou destacada. De qualquer forma, estas imagens contendo as trincas seladas foram importantes para analisar o comportamento dos algoritmos de classificação da segunda fase de processamento dos defeitos do asfalto. A pesquisa de campo permitiu também a identificação de defeitos que inicialmente não haviam sido detectados visualmente nas imagens coletadas, como foi o caso das trincas em blocos da Figura 47c. Estas trincas não estão caracterizadas nas imagens desta região demonstrando que estes padrões não foram detectados na resolução espacial (25 cm) das imagens. Da mesma forma, os poucos buracos encontrados durante a pesquisa de campo não foram caracterizados nas imagens de menor resolução espacial, Figura 46c. A falta de outras ocorrências de buracos com outras formas, tamanhos e até mesmo com outra composição espectral impediram o estudo do comportamento destes defeitos nas imagens analisadas. Casos em que os buracos são maiores e que afetam as camadas inferiores dos pavimentos, expondo os materiais das camadas inferiores devem produzir contrastes maiores e resposta espectral diferente da média da manta asfáltica da superfície do pavimento. Nestes casos, alguns buracos, limitados a resolução espacial das imagens, podem ser detectados nas imagens e nos processamentos.

6.1.1 Sobre a primeira etapa da metodologia: Detectar Asfalto

A análise preliminar da qualidade das imagens permitiu a identificação de problemas relacionados à formação da imagem digital pelo sensor, tais como: descalibração, ruído eletrônico, ausência de linhas, linhas atenuadas e saturação. No entanto, dentre os problemas identificados na formação das imagens, o que trouxe mais impacto para classificação, principalmente na primeira etapa da metodologia, foi o ruído eletrônico que ocupou a metade direita de toda a área das faixas imageadas, Figura 39b ilustra este comportamento. O resultado da classificação SAM nas áreas com ruído eletrônico gerou uma imagem classificada não uniforme, semelhante ao efeito “*salt and pepper*”, conforme ilustrado na Figura 62b.

Figura 62 – (a) Imagem espectral de um trecho com ruído eletrônico. (b) Resultado da classificação SAM para área com ruído eletrônico.

O classificador SAM é um algoritmo de classificação específico para imagens com várias bandas espectrais. Permite o uso de bibliotecas espectrais como referência para classificação dos pixels da imagem. O uso de bibliotecas evita a fase de treinamento dos classificadores supervisionados. Esta é uma característica importante para a metodologia proposta, pois permite a automação do

processamento das imagens eliminando a interferência do analista de imagens para selecionar amostras das classes.

A construção de uma biblioteca espectral se faz a partir das medições em campo ou em laboratório de amostras utilizando-se de um instrumento espectrômetro. O National Center for Remote Sensing in Transportation (NCRST) na Universidade da Califórnia de Santa Bárbara desenvolveu uma biblioteca espectral sobre asfalto e feições urbanas, mas as amostras são somente da região próxima da cidade de Santa Bárbara/USA e não representam universo de asfalto encontrado nas imagens coletas na região de Sorocaba, São Paulo. Por intermédio do autor, esta biblioteca foi cedida pelo NCRST ao Laboratório de GeoProcessamento do Departamento de Transportes da EPUSP. No entanto, a biblioteca não foi utilizada pelas seguintes razões: - o sensor estar descalibrado; - não haver correção atmosférica para transformar os valores de radiância da imagem em valores de reflectância; e, por último, o universo de amostras da biblioteca ser somente da região de Santa Bárbara nos USA. Não há registro de outra biblioteca espectral pública com amostras de asfalto utilizadas no Brasil. Para que a metodologia fosse executada com o classificador SAM, foi criada uma biblioteca espectral a partir das próprias imagens. Visualmente foram selecionadas amostras de asfalto em condições diferentes, por exemplo: asfalto claro, escuro, de trilha interna, de trilha externa, de remendo, de área com pouco movimento, etc (Figura 43). As amostras foram todas das imagens com o maior número de bandas espectrais (24 bandas) com objetivo de aumentar a capacidade de discriminação do classificador. Esta biblioteca foi aplicada tanto para as imagens de 24 bandas como para as imagens de 8 bandas. Analisando a Figura 44 com as curvas espectrais criadas a partir das imagens, verifica-se que as curvas possuem comportamento muito próximo uma das outras, diferenciando apenas pela intensidade da radiância. No entanto, para futuros trabalhos, o número de amostras da biblioteca deve ser aumentado para melhorar ainda mais a significância das amostras. Como a biblioteca espectral criada foi a partir das imagens de radiância, ela só é válida para outras imagens de radiância, carrega internamente os mesmos erros de calibração do sensor, ou seja, esta biblioteca só poderá ser utilizadas para as imagens adquiridas por este sensor e com essa configuração. A partir do instante que o sensor for recalibrado, um novo conjunto de amostra deve ser selecionado das novas imagens para criar outra biblioteca espectral de referência. Por fim, o método utilizado com o SAM foi

semelhante às outras técnicas de classificação supervisionada onde o analista de imagens fornece amostras de treinamento da própria imagem para que os classificadores funcionem corretamente. No caso do SAM foi fornecida uma biblioteca espectral coletada da própria imagem.

O experimento realizado para determinar quais filtros e em qual sequência deveriam ser aplicados, foi construído somente para a AOI-01. Se o mesmo experimento fosse repetido para outras áreas, possivelmente, outros valores poderiam ser encontrados. No entanto, a AOI-01 é uma amostra bastante representativa das feições encontradas na imagem completa. Deve ser observado em outros estudos se, para outro conjunto de imagens, rural ou urbano, os filtros e a sequência aplicada terão o mesmo desempenho. O resultado obtido com a AOI-02 indica que o desempenho dos filtros depende da cena que está sendo processada.

A utilização dos filtros Clump, Sieve e Média após a classificação inicial SAM traz vantagens e desvantagens para o resultado final da pesquisa. A principal vantagem foi a atenuação do efeito do ruído eletrônico na classificação, os filtros ajudaram a melhorar o resultado final, conforme ilustrado na Figura 63. A Tabela 28 mostra a exatidão geral antes e depois da aplicação dos filtros. A tabela mostra ainda a porcentagem da área total da imagem ocupada pelo ruído eletrônico. O desempenho dos filtros está diretamente correlacionado com as áreas que apresentam taxa elevada de ocorrência de ruído. O desempenho dos filtros depende também de outros fatores, como por exemplo, se a área apresenta mais informação urbana ou rural.

Figura 63 – (a) Resultado da classificação SAM para área com ruído eletrônico. (b) Resultado da classificação após a aplicação dos filtros.

Para a AOI-02, onde não há ruído eletrônico e também a imagem é mais homogênea, os filtros praticamente não influenciaram o resultado, apenas uma pequena alteração negativa no resultado da classificação.

Tabela 28 – Comparação da exatidão geral das áreas de interesse antes e depois da aplicação dos filtros de Clump, Sieve e Média.

	Exatidão (1)	Exatidão (12)	Diferença	Img ruído
AOI 01	91,22	92,51	1,4%	31,0%
AOI 02	95,03	94,92	-0,1%	0,0%
AOI 03	86,83	87,40	0,7%	18,0%
AOI 06	91,98	93,42	1,6%	95,0%
AOI 08	87,70	88,07	0,4%	40,0%

Figura 64 – Oitava componente principal da AOI-01 identificando o ruído eletrônico na parte inferior direita da imagem.

A aplicação do filtro da Média traz uma outra desvantagem que é o comissionamento nas bordas das áreas classificadas como asfalto. A classificação SAM discriminou corretamente o asfalto das faixas de sinalização de trânsito sobre o pavimento, mas quando o filtro da média foi aplicado, aumentou a área do asfalto incluindo as faixas de sinalização. Assim, a máscara final utilizada para separar o asfalto na imagem espectral carrega também esse erro de comissão, gerado pelo filtro da Média que estendeu a área do asfalto.

As imagens utilizadas como verdade de campo nos cálculos das matrizes de confusão foram construídas a partir da interpretação visão das próprias imagens. Há possíveis erros de interpretação que podem interferir nos números absolutos obtidos para as exatidões gerais. No entanto, esses erros não influenciam as análises comparativas dos resultados dos filtros aplicados.

Os valores de exatidão obtidos na primeira etapa da metodologia em torno de 90% são valores altos para resultados de classificadores automáticos,

demonstrando o excelente desempenho da etapa de detecção do asfalto nas imagens espectrais com a metodologia apresentada.

6.1.2 Sobre a segunda etapa da metodologia: Classificação dos Defeitos do Asfalto

A segmentação é a base para classificação orientada a objetos. É a partir do resultado da segmentação que toda a estatística dos objetos é calculada, desempenhando papel crucial no resultado e qualidade final da classificação baseada em objetos.

Entre as características mais importantes de um processo de segmentação está a homogeneidade dos objetos. Bons resultados são esperados somente se os contrastes são tratados de forma consistente (BAATZ; SCHAEPE, 2000).

Em muitos casos, a análise de imagem leva a objetos significativos apenas quando a imagem é segmentada em áreas homogêneas (BAATZ; SCHAEPE, 2000).

Na segmentação há uma relação cruzada entre a resolução espacial, a resolução espectral, os parâmetros de escala, forma e compacidade com a dimensão e a forma dos objetos que estão sob análise, ou melhor, com os atributos das classes analisadas. A segmentação é caso dependente dos objetos em estudo e das imagens utilizadas.

Segmentos de uma imagem nunca irão representar objetos significativos em todas as escalas para qualquer aplicação (BLASCHKE et al., 2000).

Toda segmentação das imagens foi realizada no programa eCognition e vários pequenos experimentos de segmentação foram realizados com os parâmetros de escala, forma e compacidade para encontrar a melhor configuração para segmentar os remendos, da mesma forma, outros experimentos foram realizados para as trincas do asfalto. Para todas as segmentações das imagens espectrais, as diferentes bandas das imagens receberam o mesmo peso, exceto para o caso das componentes principais em que as últimas bandas foram desprezadas.

A interpretação visual da segmentação das imagens para identificação dos remendos aponta para uma segmentação que conseguiu separar os remendos

existentes no asfalto. No entanto, o desempenho ruim da classificação dos remendos, neste caso, pode estar associado a grande variabilidade de formas em que os remendos acontecem. Como o treinamento do algoritmo é feito a partir da seleção de amostras de objetos que representam os remendos, o resultado final da classificação é muito dependente das amostras selecionadas. Quando o número de amostras escolhido é grande, os intervalos de confiança das funções de pertinência dos atributos da classe remendo aumentam proporcionalmente também, diminuindo o poder de discriminação do classificador. Assim sendo, percebe-se que da forma que estrutura dos atributos da classe remendo foi construída não gera um poder discriminante forte. A estratégia de ter uma só classe representando os remendos não possui desempenho aceitável. Deve ser investigada a construção de subclasses de remendos formando uma hierarquia de classe, onde cada uma destas subclasses possa ser configurada para um tipo específico de remendo e que a soma do resultado de todas estas subclasses comporiam o índice geral de remendos para a imagem em análise. Estas subclasses poderiam ser instanciadas em conjuntos de objetos que apresentam intervalos de confiança estreitos para as funções de pertinência dos atributos da classe. Possivelmente, cada subclasse mereceria uma segmentação diferente para privilegiar os objetos que estão sendo tratados pela mesma.

Para o caso da classificação dos defeitos do tipo trinca, a segmentação das imagens teve uma influencia maior sobre os resultados encontrados. O mesmo comportamento do segmentador obtido no experimento mostrado na tabela 18 não foi repetido para outras imagens e nem mesmo para outras regiões da mesma cena.

A dimensão das trincas frente à resolução espacial das imagens é o fator limitante para obtenção de objetos consistentes ao longo de toda a imagem e até mesmo em outras imagens semelhantes.

“A regra básica é que a escala dos objetos de imagem a serem detectados deve ser significativamente maior do que a escala do ruído da imagem em relação à textura. Isso garante que o processamento de imagem orientado a objeto subsequente esteja baseado em objetos de imagem significativos” (BLASCHKE et al., 2000).

“Além disso, a segmentação resultante deve ser reproduzível e universal para permitir a aplicação em uma grande variedade de dados” (BLASCHKE et al., 2000). Este comportamento não foi observado em nenhum dos dois conjuntos de

parâmetros utilizados para segmentar as imagens. Inicialmente, acreditava-se que a contribuição espectral durante a segmentação pudesse influenciar positivamente o segmentador aumentando sua capacidade de separar melhor as formas de interesse mesmo em um imagem com resolução espacial desfavorável à dimensão destes objetos. Hipótese esta que não foi comprovada com os resultados obtidos.

Mesmo sem uma segmentação apropriada para a classificação dos objetos, da mesma forma que os remendos, a classe Trinca Longa deve ser reconstruída na forma de uma hierarquia de subclasses do tipo trinca, onde cada subclasse pudesse representar um tipo específico de trinca visto nas imagens. A soma de todas as subclasses representaria a classe Trinca e comporia o índice de trincas para a imagem sob análise.

Os resultados apresentados na tabela 20 não são representativos da quantidade de trincas encontrados nas imagens analisadas. Servem para demonstrar que com as imagens nesta resolução espacial não é possível estabelecer uma metodologia sistemática para quantização do número de trincas e suas respectivas áreas.

Com objetivo de avaliar a utilização das componentes principais na classificação dos defeitos do asfalto, as imagens foram transformadas e utilizadas no processo da segunda etapa da metodologia. No entanto, somente as componentes principais 1, 2, 3 e 4 foram utilizadas na classificação, as demais componentes não possuíam informação nem de remendos e nem das trincas. A mesma estrutura de classe foi utilizada para a classificação com as componentes principais, reconstruindo os intervalos de confiança das funções de pertinência dos atributos das classes, pois novas segmentações foram realizadas para cada caso. As classificações utilizando as componentes principais no lugar das bandas espectrais não apresentaram melhoria dos resultados encontrados. Na classificação dos remendos do asfalto, o classificador piorou ainda mais o seu desempenho. A segmentação e classificação das componentes principais sofreram com os mesmos problemas relatados para o caso das bandas espectrais.

6.2 Sugestões para trabalhos futuros

A seguir são apresentadas sugestões relevantes para trabalhos futuros que vão desde a continuação e melhoria da pesquisa iniciada até a adaptação do sensor a outra plataforma de sensoriamento remoto.

- Pesquisar as melhores bandas espectrais para serem utilizadas na classificação do asfalto em imagens hiperespectrais independente de sensor, plataforma e faixa espectral.
- Pesquisar a utilização das componentes principais em conjunto com as bandas espectrais estabelecendo fatores de ponderação para cada banda e componente com o objetivo de aumentar o poder dos segmentadores.
- Pesquisar a criação de uma transformação linear dedicada ao asfalto, da mesma forma que existem eixos específicos dos dados espectrais que podem ser interpretados como “componentes de vegetação”, poderia ser estudado um eixo específico para o asfalto.
- Pesquisar a remoção do ruído das imagens através da transformação direta das componentes principais; filtrar das últimas componentes o ruído por meio de técnicas de processamento de imagens como a Transformada Rápida de Fourier e depois fazer a transformação inversa das componentes principais em bandas espectrais.
- Investigar o uso da biblioteca espectral da UCSB em imagens do AVIRIS para o Brasil.
- Investigar a adaptação do sensor hiperespectral a uma plataforma terrestre móvel. Nesta configuração seria possível gerar imagens de altíssima resolução espacial e alta resolução espectral, pois a velocidade da plataforma terrestre seria muito menor do que a velocidade de stall da plataforma aérea.
- Investigar o uso da segunda parte da metodologia de Classificação dos Defeitos do Asfalto em imagens produzidas por câmeras digitais comerciais (14 mega pixels ou mais). As câmeras seriam adaptadas em uma haste de elevação para capturar imagens da área (6m x 3m) necessária ao levantamento do IGG manual.

7 Conclusão

O mercado de sensoriamento remoto vem crescendo ao longo dos últimos anos. As novas tecnologias, os novos sistemas e as novas ferramentas desempenham papel importante na popularização do uso de imagens de sensoriamento remoto. As novas plataformas e sensores vêm produzindo imagens de alta qualidade e, cada vez mais, com melhor resolução tanto espacial como espectral. A tendência da evolução tecnológica aponta para um futuro próximo em que teremos imagens com melhor resolução e com maior poder discriminante do que temos hoje.

Neste sentido, estar preparado com tecnologia e metodologias de processamento, tratamento e classificação que sejam capazes de tratar as futuras imagens de sensoriamento remoto é um desafio que pode ser trabalhado desde já.

A obtenção de imagens com características espectrais e espaciais suficientes para o desenvolvimento da pesquisa foi um desafio encontrado durante a execução dos trabalhos. As imagens utilizadas da região de Sorocaba não possuem a diversidade de amostras dos defeitos dos pavimentos desejada, mas serviram substancialmente para validar toda a metodologia da primeira fase de classificação e separação do asfalto. Para a segunda fase da metodologia, a resolução espacial desempenhou papel limitante para o tipo de análise pretendida com a pesquisa, apesar das imagens possuírem alta resolução espacial para os padrões atuais de sensoriamento remoto, não foi possível classificar e segmentar de forma sistemática as imagens. Os resultados obtidos para uma imagem não se repetiam para outra imagem, até mesmo para outra região da própria cena. A segmentação da segunda etapa representou o desafio maior para a pesquisa. Os objetos de interesse nas imagens, principalmente trincas, são muito menores que a resolução espacial das imagens. Neste caso, a resolução espectral das imagens não influenciou a capacidade de segmentação da ferramenta utilizada para segmentar as imagens. A segmentação foi realizada muito próxima do nível do pixel e os objetos resultantes da segmentação não apresentaram um comportamento sistemático.

Mesmo não havendo o levantamento correto da quantidade de defeitos do asfalto contidos nas imagens foi possível demonstrar que a metodologia proposta e as ferramentas disponíveis permitem que sejam gerados índices de ocorrência de defeitos a partir das imagens, contabilizando a quantidade de objetos de imagens que apresentam os defeitos do asfalto em relação a quantidade total de asfalto contida nas imagens. Em função do resultado obtido na segunda etapa não apresentar corretamente os defeitos do asfalto, não foi possível correlacionar os índices calculados com o IGG/IGGE.

A metodologia da segunda etapa de classificação pode ser adaptada e utilizada para imagens produzidas por câmeras digitais comerciais e servirem de registro automático das áreas de levantamento que são utilizadas nos cálculos do levantamento do IGG. Desta forma, ao invés do analista de campo anotar na planilha de registro de defeitos, uma foto poderia ser capturada a partir de uma haste de elevação e, esta foto, posteriormente, ser processada por um sistema computadorizado que implementa a metodologia elaborada neste trabalho.

Com a mudança de plataforma de sensoriamento de um motoplanador para helicóptero, imagens com maior resolução espacial e espectral podem ser geradas, ou o uso de aeronaves não tripuladas que tenham a capacidade de voar mais baixo e com velocidade menor para aquisição de imagens podem ser consideradas como uma possível solução para a aquisição de imagens que atendam às necessidades do levantamento da condição do asfalto utilizando a metodologia proposta. Em contrapartida, o custo da hora de voo de um helicóptero é maior do que o custo da hora de voo de um motoplanador, o custo seria proibitivo para levantamento de grandes áreas, mas, no entanto, pode ser a solução para levantamento rápido e sistemático de pequenas áreas.

Com tanta resolução espacial, pode-se questionar a necessidade de um sistema e uma metodologia para levantar os defeitos dos pavimentos, pois, nestas condições, os defeitos estariam visíveis nas imagens para o foto intérprete. A vantagem está na sistematização da interpretação das informações geradas, retirando a subjetividade das interpretações visuais realizadas pelos fotointérpretes. Poderia ainda, no futuro, ser criados novos patamares de avaliação além dos existentes hoje (ótimo, bom, regular, ruim e péssimo). Outra vantagem está no fato que com o surgimento de sistemas que consigam gerar imagens nas resoluções necessárias e a um custo viável, a quantidade de informação produzida será

gigantesca, inviabilizando o uso de analista ou fotointérprete para analisarem as imagens. Assim, será necessário o uso de um sistema computacional com metodologia de classificação que faça os cálculos automaticamente para a enorme massa de dados gerada.

O resultado esperado da pesquisa deste trabalho foi investigar o uso de imagens espectrais no monitoramento das condições do uso dos pavimentos rodoviários tendo como objetivos:

1. Elaborar uma metodologia de extração automática das vias asfaltadas a partir de imagens hiperespectrais, utilizando-se de uma classificação híbrida, pixel a pixel e baseada em objetos;
2. Investigar quais defeitos dos pavimentos flexíveis são detectáveis pelas imagens propostas na pesquisa;
3. Elaborar uma base de conhecimento capaz de identificar e classificar as ocorrências dos principais defeitos nos pavimentos flexíveis, observáveis nas imagens de alta resolução espacial, fazendo uso intensivo das técnicas de classificação baseadas em objetos;
4. Gerar índices da qualidade do asfalto a partir das imagens e que possam ser comparados com índices já normatizados pelos órgãos competentes do país.

Sendo um trabalho de investigação, de modo geral, os objetivos traçados para o trabalho foram alcançados. Há espaço para investigação e melhoria nos objetivos 2 e 3 descritos acima. Com outras amostras de imagens e com outras resoluções espaciais é possível aprofundar mais os estudos e determinar claramente quais os defeitos são detectáveis na imagem, além dos remendos e trincas longas investigados ao longo deste trabalho. Da mesma forma, com melhorias nas classes e com a construção de uma hierarquia de classes para classificador baseado em objetos, conforme discutido no capítulo anterior, bem como, novas amostras de defeitos é possível melhorar a base de conhecimento para classificação dos defeitos do asfalto.

Independentemente dos resultados encontrados com o conjunto de imagens analisadas, o ponto principal do trabalho está na proposição da metodologia que utiliza as melhores técnicas existentes de classificação de imagens, misturando a classificação pixel a pixel com a classificação baseada em objetos.

A utilização de imagens espectrais de aerolevanteamento para a medição das condições dos pavimentos é uma pesquisa inédita no país. Existem trabalhos semelhantes no exterior utilizando imagens espectrais para avaliar os pavimentos, entretanto não propõem uma metodologia sistematizada como a que foi desenvolvida neste trabalho.

Em síntese, tendo as imagens mais resolução espacial, até mesmo em detrimento da resolução espectral, é possível calcular um índice de qualidade do asfalto a partir de imagens. A metodologia apresentada em conjunto com novos sistemas de levantamento permitirão o desenvolvimento de ferramentas poderosas de planejamento, acompanhamento e aferição de obras para os órgãos que administram e gerenciam as rodovias brasileiras.

REFERÊNCIAS

AGÊNCIA NACIONAL DE TRANSPORTES TERRESTRES – ANTT. Anuário Estatístico dos Transportes Terrestres – AETT/2008. Disponível em: <http://www.antt.gov.br/InformacoesTecnicas/aett/aett_2008/principal.asp>. Acesso em: 12 jun. 2009.

ATECH – Fundação Aplicações Tecnologias Críticas. Imagem sensor CASI 1500 da cidade de Mogi Guaçu, SP, Brasil, 2007.

ATECH – Fundação Aplicações Tecnologias Críticas. Imagem sensor CASI 1500 da região sul da cidade de Sorocaba, SP, Brasil, 2010.

BAATZ, M.; SCHAPE, A, Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation. 2000. Disponível em: <www.ecognition.com/document>. Acesso em: 03 maio 2010.

BENZ, U.C.; HOFMANN, P.; WILLHAUCK, G. LINGENFELDER, I.; HEYNEN M. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS ready information. ISPRS Journal of Photogrammetry and Remote Sensing 58, 2004. 239-258p.

BERNUCCI, L. B.; MOTA, L. M. G.; CERATI, J. A. P.; SOARES, J. B. Pavimentação Asfáltica: Formação Básica para Engenheiros. Rio de Janeiro: Abeda, 2008.

BLASCHKE, T.; KUX, H. Sensoriamento remoto e SIG avançados: novos sistemas sensores métodos inovadores. São Paulo: Oficina de Textos, 2005. 286p.

BLASCHKE, T.; LANG, S.; HAY, G. J. Object-Based Image Analysis, Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Springer, ISBN: 978-3-540-77057-2, 2008.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications, 2000.

BLASCHKE, T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GeoBIT/GIS 6:12-17, 2001.

BOARDMAN, J. W. Spectral angle mapping: a rapid measure of spectral similarity (in preparation), 1993.

CAMPBELL, J. B. Introduction to Remote Sensing, Guildford press, 4 ed., 2007. 626p.

CANADA CENTRE FOR REMOTE SENSING - CCRS. Fundamentals of Remote Sensing. Disponível em: <http://www.ccrs.nrcan.gc.ca/resource/tutor/fundam/index_e.php>. Acesso em: 03 maio 2009.

CANADA CENTRE FOR REMOTE SENSING - CCRS. Glossary. Disponível em: <http://www.ccrs.nrcan.gc.ca/glossary/index_e.php>. Acesso em: 03 maio 2009.

CANTY, M. J. Image Analysis, Classification and Change Detection in Remote Sensing: with algorithms for ENVI/IDL. CRC Press, 2007.

CARRERE V., CONEL E. J., Recovery of atmospheric water vapor total column abundance from imaging spectrometer data around 940 nm -- sensitivity analysis and application to Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) data, 1993. Disponível em: <<http://www.sciencedirect.com/science/article/B6V6V-489S4HM-14/2/de9056f6150288da24022cacfcc2a3cc>>. Acesso em: 30 maio 2010.

CLARK, R. N., Spectroscopy of Rocks and Minerals, and Principles of Spectroscopy, in Manual of Remote Sensing, Volume 3, Remote Sensing for the Earth Sciences, (A.N. Rencz, ed.) John Wiley and Sons, New York, p 3- 58, 1999.

CONFEDERAÇÃO NACIONAL DOS TRANSPORTES, Pesquisa Rodoviária CNT 2007. Disponível em: <<http://sistemacnt.cnt.org.br/>>. Acesso em: 12 jun. 2009.

CONFEDERAÇÃO NACIONAL DOS TRANSPORTES, Pesquisa Rodoviária CNT 2009. Disponível em: <<http://www.cnt.org.br/portal/webCNT>>. Acesso em: 21 jun. 2010.

CROSTA, Á. P. Processamento Digital de Imagens de Sensoriamento Remoto. Ed. Rev. -Campinas, SP: IG/UNICAMP, 1993.

DEFINIENS, eCognition User's Guide 4. Definiens Imaging. 2004

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES, NORMA DNIT 005/2003 – TER, Defeitos nos pavimentos flexíveis e semi-rígidos Terminologia, 2003. 12p.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES, NORMA DNIT 006/2003 – PRO, Avaliação objetiva da superfície de pavimentos flexíveis e semi-rígidos - Procedimento, 2003. 10p.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES, NORMA DNIT 007/2003 – PRO, Levantamento para avaliação da condição de superfície de subtrecho homogêneo de rodovias de pavimentos flexíveis e semi-rígidos para gerência de pavimentos e estudos e projetos Procedimento, 2003. 11p.

FISCHER, W. A.; HEMPHILL, W. R.; KOVER, A. Progress in Remote Sensing. Photogrammetria, vol. 32, 1976.

FLORENZANO, T. G. Imagens de satélites para estudos ambientais. São Paulo: Oficina de Textos, 2002.

GOMEZ, R. B. Hyperspectral imaging: a useful technology for transportation analysis, George Mason University School of Computational Sciences, Center for Earth Observing and Space Research, Virginia, 2002.

GONZALES, R. C.; WOODS, R. E. Digital Image Processing. Addison-Wesley, Reading, 1993. 716 p.

HARALICK, R. M.; SHAPIRO, L. G. Computer and robot vision. Vol. I, Addison-Weasley, Reading, 1992. 672 p.

HAY, G.J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA). In: Blaschke T, Lang S, Hay GJ (eds) Object-Based Image Analysis – Spatial concepts for knowledge-driven remote sensing applications. Springer-Verlag, Berlin, 2008.

HAY, G.J.; CASTILLA, G. Object-Based Image Analysis: Strengths, Weaknesses, Opportunities and Threats (SWOT). In: International Archives of hotogrammetry, Remote Sensing and Spatial Information Sciences, Vol. No. XXXVI-4/C42, Salzburg, 2006.

HEROLD, M.; ROBERTS, D.; SMADI, O.; NORONHA, V. Road Condition Mapping With Hyperspectral Remote Sensing.

HEROLD, M.; ROBERTS, D.; NORONHA, V.; SMADI, O., Imaging spectrometry and asphalt road surveys, Transportation Research Part C: Emerging Technologies, 2008

HEROLD, M.; GARDNER, M. E.; NORONHA, V.; ROBERTS, D. Spectrometry and hyperspectral remote sensing of urban road infrastructure.

HOUAISS, A. Dicionário Houaiss Da Língua Portuguesa, Objetiva, 2007. 3008p.

INTERMAP. History of Aerial Maps Timeline. Disponível em: <<http://www.intermap.com/blog/history-of-aerial-maps-timeline>>. Acesso em: 17 fev. 2009.

KRUSE, F. A.; LEFKOFF, A. B.; BOARDMAN, J. W.; HEIDEBRECHT, K. B.; SHAPIRO, A. T.; BARLOON, P. J.; GOETZ, A. F. H. The Spectral Image Processing System (SIPS) - Interactive Visualization and Analysis of Imaging Spectrometer Data, Remote Sensing of Environment, vol. 44, 1993, pp. 145-163.

LANG, S. Object-based image analysis for remote sensing applications: modeling reality - dealing with complexity, Centre for Geoinformatics (Z GiS). Paris-Lodron: University Salzburg, 2008.

LILLESAND, T.M. ; KIEFER, R.W.; CHIPMAN, J. W. Remote Sensing and Image Interpretation. 6th Edition. John Wiley & Sons, 2007. 756p.

MARANGOZA, A. M.; ORUCA, M.; BUYUKSALIH, G. Object-Oriented Image Analysis And Semantic Network For Extracting The Roads And Buildings From Ikonos Pan-Sharpned Images.

MCNEILL, M. Fuzzy Logic. A pratical approach. Academic Press, Inc, 1994.

MIRANDA, E. E. de; (Coord.). Brasil em Relevo. Campinas: Embrapa Monitoramento por Satélite, 2005. Disponível em: <<http://www.relevobr.cnpm.embrapa.br>>. Acesso em: 23 jun. 2009.

MIRANDA, E. E. de; COUTINHO, A. C. (Coord.). Brasil Visto do Espaço. Campinas: Embrapa Monitoramento por Satélite, 2004. Disponível em: <<http://www.cdbrasil.cnpm.embrapa.br>>. Acesso em: 22 jun. 2009.

NASA, NASA Earth Observatory Glossary. Disponível em: <<http://earthobservatory.nasa.gov/Glossary/>>, Acesso em: 03 maio 2009.

NASA, Shuttle Radar Topography Mission (SRTM). Disponível em: <<http://srtm.usgs.gov/mission.php>>. Acesso em 16/05/2009.

NEUBERT, M.; HEROLD, H.; MEINEL, G. Evaluation of Remote Sensing Image Segmentation Quality – Further Results and Concepts. 2006.

NOBREGA, R. A. A. Detecção da malha viária na periferia urbana de São Paulo utilizando imagens de alta resolução espacial e classificação orientada a objetos. Tese Doutorado. Escola Politécnica, Universidade de São Paulo, 2007.

NOBREGA, R. A. A.; OHARA, C. G.; QUINTANILHA, J. A. An object-based approach to mine roads over informal settlements in Sao Paulo city. In: Blaschke, T., Lang, S., Hay, G. (eds.). (Org.). Object based image analysis. Berlin: Springer, Heidelberg, Berlin, New York, 2008, v. 1, p. 595-613.

NOVO, E. M. L. de M. Sensoriamento Remoto: Princípios e Aplicações. Editora Edgar Blücher Ltda. São José dos Campos, 1989. 308p.

PINHEIRO, E. S.; KUX, H. J. H. Imagens Quickbird Aplicadas ao mapeamento do Uso e Cobertura da Terra do Centro de Pesquisas e Conservação da Natureza Pró-Mata. In Sensoriamento Remoto e SIG: Novos Sistemas e Sensores: Métodos Inovadores. São Paulo, Oficina de Textos, 2005, 286p.

QUINTANILHA, J. A. ; OHARA, C. G. ; NOBREGA, R. A. A. . Detecção de vias em áreas na periferia de São Pulo através de classificação em imagens orbitais baseada em objetos. In: XX ANPET - Congresso de Pesquisa e Ensino em Transportes, 2006, Brasília. Anais do XX ANPET - Congresso de Pesquisa e Ensino em Transportes, 2006. v. 1. p. 679-690.

RESENDE, M. R.; JORGE, S. C. H.; LONGHITANO, G. A.; QUINTANILHA, J. A. Use of hyperspectral and high spatial resolution image data in an asphalted urban road extraction. IEEE International Geoscience & Remote Sensing Symposium -

IGARSS2008, 2008, Boston, Massachusetts, U.S.A.. Proceedings of IGARSS2008, 2008.

RODRIGUES, L. M.; RESENDE, M. R.; TIMOSZCZUK, A. P. Sistema de imageamento hiperespectral de alta resolução embarcado em plataforma aérea de baixo custo, XIII Simpósio Brasileiro de Sensoriamento Remoto – SBSR, Florianópolis – SC, 2007.

SCHOWENGERDT, R. A. Techniques for Image Processing and Classification in Remote Sensing. University of Arizona. 1983. 249p

SHORT, N. M. The Remote Sensing Tutorial. NASA/Goddard Space Flight Center, 2009. Disponível em: <<http://rst.gsfc.nasa.gov/>>. Acesso em: 22 junho 2009.

UNIVERSIDADE DA CALIFÓRNIA DE SANTA BÁRBARA, National Center for Remote Sensing in Transportation (NCRST); Disponível em: <<http://www.ncgia.ucsb.edu/ncrst/>> . Acesso em: 20 jan. 2009.

YI, J. L. R.; SHIMABUKURO, Y. E.; QUINTANILHA, J. A. Identificação e mapeamento de áreas de milho na região sul do Brasil utilizando imagens MODIS. 2007.