

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL

ANDRÉ BIFFE DI RENZO

**DESENVOLVIMENTO DE METODOLOGIA PARA
MONITORAMENTO REMOTO DE RODOVIAS - VANTRod**

DISSERTAÇÃO DE MESTRADO

CURITIBA

2017

ANDRÉ BIFFE DI RENZO

**DESENVOLVIMENTO DE METODOLOGIA PARA
MONITORAMENTO REMOTO DE RODOVIAS - VANTRod**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Ciências” – Área de Concentração: Fotônica Em Engenharia.

Orientador: Prof. Dr. Jean Carlos Cardozo da Silva

Co-orientador: Prof. Dr. Cicero Martelli

CURITIBA

2017

Dados Internacionais de Catalogação na Publicação

D598d Di Renzo, André Biffe
2017 Desenvolvimento de metodologia para monitoramento remoto
remoto de rodovias : VANTRod / André Biffe Di Renzo.-- 2017.
96 f. : il. ; 30 cm

Texto em português com resumo em inglês
Disponível também via World Wide Web
Dissertação (Mestrado) – Universidade Tecnológica Federal
do Paraná. Programa de Pós-graduação em Engenharia Elétrica
e Informática Industrial, Curitiba, 2017
Bibliografia: f. 88-93

1. Rodovias. 2. Aeronave não-tripulada. 3. Processamento de
sinais – Técnicas digitais. 4. Algoritmos computacionais. 5. Rodovias – Medidas de segurança. 6. Rodovias – Sinalização. 7. Rodovias – Conservação. 8. Engenharia elétrica – Dissertações. I. Silva, Jean Carlos Cardozo. II. Martelli, Cicero. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

CDD: Ed. 23 – 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba
Bibliotecário : Adriano Lopes CRB9/1429

TERMO DE APROVAÇÃO DE DISSERTAÇÃO Nº 774

A Dissertação de Mestrado intitulada “**Desenvolvimento de Metodologia para Monitoramento Remoto de Rodovias - VANTRod**” defendida em sessão pública pelo(a) candidato(a) **André Biffe Di Renzo**, no dia 20 de outubro de 2017, foi julgada para a obtenção do título de Mestre em Ciências, área de concentração Fotônica em Engenharia, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial.

BANCA EXAMINADORA:

Prof(a). Dr(a). Jean Carlos Cardozo da Silva- Presidente – (UTFPR)

Prof(a). Dr(a). Lélío Antônio Teixeira Brito - (PUCRS)

Prof(a). Dr(a). Marco José da Silva - (UTFPR)

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 20 de outubro de 2017.

AGRADECIMENTOS

Inicialmente agradeço a Deus e Nossa Senhora Aparecida a conhecimento adquirido no desenvolvimento desse trabalho, assim como, agradeço a todos os professores que puderam proporcionar o ganho desse conhecimento.

Aos amigos que em várias situações dispuseram de seu tempo para ajudar na solução de problemas no desenvolvimento do trabalho.

Aos orientadores Jean Carlos Cardozo da Silva e Cicero Martelli por todo conhecimento fornecido e pela grande oportunidade de desenvolver essa dissertação.

Aos meus pais, minha irmã e demais familiares que de alguma forma ou de outra puderam contribuir na conclusão dessa etapa.

A minha namorada que em todos os momentos me apoiou no desenvolvimento do trabalho.

À toda a equipe da empresa Triunfo Concebra, em especial ao Rogério Vargas Cezimbra, por disponibilizar os equipamento e auxílio financeiro para o desenvolvimento do trabalho, além de disponibilizar colaboradores para acompanhar nossas visitas a empresa.

Agradeço o apoio financeiro fornecido pela Fundação Araucária, Secretaria de Estado da Ciência, Tecnologia e Ensino Superior do Paraná (SETI), CNPq, CAPES, FINEP, FUNTEF, ANTT e Triunfo Concebra. Este projeto é desenvolvido em parceria com a Triunfo Concebra (01-2015) regulado pela ANTT.

RESUMO

DI RENZO, André Biffe. Desenvolvimento de Metodologia para Monitoramento Remoto de Rodovias - VANTRod. 2017. 96 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

Rodovias são as principais vias de locomoção do Brasil, tanto de cargas como de passageiros. Pelo fato dessas rodovias estarem sujeitas a desgastes com o tempo e devido ao grande tráfego de cargas pesadas, é preciso um constante monitoramento do estado do pavimento e das sinalizações rodoviárias. Normalmente a análise do estado atual de rodovias é efetuada de forma manual, sendo necessário o deslocamento de pessoas para verificação. Uma alternativa para efetuar esse processo é o uso de imagens aéreas. Este trabalho apresenta uma metodologia de monitoramento remoto de rodovias a partir de imagens aéreas e a aplicação de técnicas de processamento digital de imagens (PDI), como uma ferramenta para verificação das condições da malha rodoviária, desde seu pavimento até as sinalizações horizontais. A aquisição dessas imagens é efetuada através de Veículo Aéreo Não Tripulado (VANT), possibilitando a varredura de grandes áreas em curto espaço de tempo. Em conjunto com as imagens adquiridas, são empregadas técnicas de PDI e reconhecimento de padrões para extrair e identificar parâmetros em rodovias. Assim, desenvolveu-se um algoritmo que processa e extrai informações da via a partir das imagens adquiridas, proporcionando maior agilidade e precisão na inspeção de rodovias. O algoritmo desenvolvido é dividido em três partes, sendo a primeira a segmentação da rodovia na imagem adquirida, a segunda a segmentação de objetos contidos na rodovia e a terceira a classificação dos objetos segmentados. Para classificar os objetos segmentados é utilizado o classificador *Support Vector Machine* (SVM) em conjunto com o descritor de Histograma Orientado ao Gradiente (HOG) para extrair características dos objetos a serem classificados. Com esse algoritmo desenvolvido obteve-se resultados positivos na obtenção de informações da rodovia a partir de imagens aéreas. Em testes de desempenho efetuado, houve taxa de acerto de 97,37% para as classes de objetos selecionadas, demonstrando assim, que a metodologia proposta pode ser aplicada em ambiente real, auxiliando equipes de manutenção e gerenciamento de rodovias.

Palavras-chave: Monitoramento de Rodovias, Veículo Aéreo Não Tripulado, Processamento Digital de Sinais

ABSTRACT

DI RENZO, André Biffe. Development of highway remote sensing methodology - VANTRod 96 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

Highways are the principal transportation modal way in Brazil for cargo and passengers. Highways can suffer wear due to weather and traffic load, hence necessary a constant monitoring of the pavement and traffic signalization health. In general, the highway health is monitored manually being necessary persons to make the verification process. One alternative to this process is the use of aerial images. This work presents a highway remote sensing methodology from aerial imagens and digital image processing (DIP), as a tool to verify the road conditions, including the pavement and road markings. The acquisition of images are performed by an Unmanned Aerial Vehicle (UAV) enabling large area scans with less time. With the acquired imagens, DIP techniques and pattern recognition are employed to extract and identify highways parameters. So, an algorithm was developed to process and extract road information of the acquired images providing inspection of highway with agility and precision. The developed algorithm has three parts: the first one make the roadway segmentation, the second segments objects of the road and the third classifies the segmented objects. To classify the segmented objects, the Histogram of Oriented Gradient (HOG) descriptor has been used to extract characteristics of the objects and the Support Vector Machine (SVM) was used to classify the objects. With this developed algorithm, positive results has reached in obtain road information from the aerial images. Performance tests has been performed and a hit rate of 97.37% was reached for the selected classes, proving the ability of this proposed methodology could be applied in real environment helping maintenance and management highway teams.

Keywords: Highway Monitoring, Unmanned Aerial Vehicle, Digital Image Processing.

LISTA DE FIGURAS

Figura 1 - Condições das rodovias pavimentadas no Brasil.....	16
Figura 2 - Exemplo de sistema de inspeção veicular de asfalto. (a) veículo instrumentado, (b) Interface homem máquina, (c) Imagens do ambiente a ser monitorado, (d) Imagens processadas.	24
Figura 3 - Modelo de uma rodovia em imagens aéreas de SR. Esse modelo apresenta características da rodovia como um todo (escala abrangente) e de seus componentes (escala fina). Cada bloco do modelo apresenta uma característica da rodovia.	27
Figura 4 - Imagem de exemplo. (a) Imagem de alta resolução, (b) Imagem de baixa resolução.	30
Figura 5 – Formação de nova imagem a partir de informações em diferentes espaços de cores da imagem original. A imagem apresenta três bandas de cores transferidas da imagem original onde (a) apresenta a 1ª componente da transformada PCA, (b) canal de saturação do espaço de cores HSI, (c) componente C_b do espaço de cores YC_bC_r e (d) resultado da composição das três imagens.....	30
Figura 6 - Segmentação não supervisionada da imagem. (a) apresenta o componente “ C_b ” com contraste aprimorado, (b) o resultado da segmentação, (c) a superfície de rodovia segmentada e (d) as laterais da rodovia suavizadas.	31
Figura 7 - Detecção de marcações horizontais, onde (a) apresenta a 1ª componente da transformada PCA da imagem original, (b) o resultado do filtro anisotrópico Gaussiano, (c) as marcações extraídas e (d) as marcações geradas e sobrepostas na rodovia extraída.....	32
Figura 8 - Espaço de cores RGB. O cubo (a) apresenta as tonalidades de cores mais escuras, (b) as tonalidade mais claras e (c) apresenta como o valor de um pixel é representado nesse espaço de cores.	33
Figura 9 - Espaço de cores YC_bC_r . O eixo central Y apresenta a variação do brilho na vertical. Nesta figura o plano inferior possui $Y = 0$, o plano central com $Y = 0,5$ e o plano superior com $Y = 1$. Os componentes C_b e C_r variam na horizontal formando um plano com valores em 0 e 1.	35
Figura 10 - Representação do espaço de cores HSV por um cone. Nessa figura, o canal H (Hue) representa todo o espaço de cores variando de 0° a 360° . Para apresentar a variação dos canais S	

(saturação) e V (brilho) o cone está seccionado, sendo possível visualizar o resultado da variação dos parâmetros S e V	36
Figura 11 - Funções Fuzzy para cada canal do espaço de cores HSV com suas respectivas faixa de valores. (a) Funções de pertinência para o canal H . (b) Representação das cores definidas pelas funções de pertinência de H . (c) Funções de pertinência do canal S . (d) Representação das cores definidas pelas funções de pertinência de S . (e) Funções de pertinência do canal V . (f) Representação das cores definidas pelas funções de pertinência de V	39
Figura 12 - Exemplo de máscara gaussiana 5 x 5 e seus coeficientes.....	41
Figura 13 – Máscaras utilizadas para detecção de bordas. Máscara de Prewitt: horizontal (a), vertical (b). Máscara de Sobel: horizontal (c), vertical (d). Máscara de Roberts (e) e (f).	41
Figura 14 - Exemplo de máscara em uma imagem. (a) apresenta a imagem original, (b) os pixels da seção da imagem sob a máscara e (c) os coeficientes do filtro. Nesse exemplo a máscara possui dimensão 3 x 3.....	44
Figura 15 - Conjunto onde são apresentados alguns ES comumente usados, onde (a) representa o ES em cruz, (b) o quadrado, (c) o retângulo e (d) uma elipse. Cada quadrado dos ES representados é um pixels. O ponto preto indica o centro do ES.	45
Figura 16 - Operações morfológicas em um objeto. O ES é o círculo com um ponto central marcado. (a) Objeto; (b) Procedimento de erosão; (c) Resultado da erosão; (d) Procedimento de abertura; (e) Resultado da abertura; (f) Procedimento de dilatação; (g) Resultado da dilatação; (h) Procedimento de fechamento; (i) Resultado do fechamento.....	47
Figura 17 - Exemplo de descritor HOG. (a) Imagem original, (b) Bordas da imagem, (c) Células 8 x 8, (d) Agrupamento de histogramas em blocos 3 x 3.....	49
Figura 18 - Exemplo de conjunto de dados e hiperplano ótimo. Círculos em vermelho pertencem a classe 1 e círculos pretos a classe 2. As amostras preenchidas representam as amostras com maior complexidade de serem classificadas. Os eixos y_1 e y_2 indicam as características das amostras.....	50
Figura 19 - VANT com câmera acoplada utilizado para aquisição das imagens.....	53
Figura 20 - Telas do aplicativo para pilotagem do VANT. (a) Tela principal que contém informações de todos os instrumentos, (b) Configurações de bateria, (c) Registro de voo, (d) Revisão de voo.	54
Figura 21 - Softwares utilizados para adquirir imagens e gerar ortomosaicos. (a) Aplicativo para dispositivo móvel Pix4Dcapture. Na tela apresentada é possível marcar a área onde o VANT sobrevoará para aquisição das imagens, configurar a altura de voo e visualizar informações dos	

instrumentos do VANT. Em (b) é apresentado o software para processamento das imagens adquiridas. A tela em (b) demonstra um ortomosaico gerado no software Pix4Ddesktop.	55
Figura 22 - Fluxograma de execução do algoritmo desenvolvido. A legenda no canto superior direito indica o tipo de imagem de acordo com a cor do bloco. Cada bloco é identificado por um número que indica a ordem das operações executadas.....	58
Figura 23 - Resultado da etapa de segmentação da rodovia. Cada número abaixo da figura representa a etapa no fluxograma do algoritmo apresentado na Figura 22.	60
Figura 24 - Resultado da identificação de objetos. Cada número abaixo da figura representa a etapa no fluxograma do algoritmo apresentado na Figura 22.	65
Figura 25 - Testes de segmentação de rodovia e objetos em ambiente controlado. Retângulos em azul indicam objetos identificados	69
Figura 26 - Geração de ortomosaico. (a) e (b) são imagens adquiridas para gerar o ortomosaico. (c) ortomosaico gerado com os objetos com os objetos identificados em azul. (d) ampliação de um ponto da imagem (c).....	71
Figura 27 - Testes de segmentação de rodovia e objetos em ambiente real. Retângulos azuis indicam objetos identificados.	72
Figura 28 - Exemplo de objetos para treinamento e teste. (a) Carros, (b) Traços, (c) Escrita, (d) Setas, (e) defeitos.....	74
Figura 29 - Testes de identificação em ambiente controlado. (a) e (b) são frames de vídeos que foram adquiridos. (c) é o resultado de identificação do ortomosaico apresentado na Figura 26 (c). Objetos marcados em verde foram identificados como setas, em vermelho traços, azul carros e magenta defeitos.	76
Figura 30 - Testes de classificação em ambiente real. Objetos marcados em verde foram identificados como setas, em vermelho traços, azul carros, palavras em amarelo e magenta defeitos.	77
Figura 31 - Teste de classificação de ortomosaico gerado de ambiente real com área de 0.0042 km ² . Objetos marcados em verde foram identificados como setas, em vermelho traços, azul carros, palavras em amarelo e magenta defeitos.....	78
Figura 32 - Erro de segmentação de objetos. (a) Objetos conectados. (b) Sobreposição de objetos.....	79
Figura 33 – Erro na segmentação de asfalto. (a) Imagem original, (b) Segmentação por cor, (c) Pavimento segmentado após análise dos segmentos selecionados como sendo pavimento.....	80
Figura 34 - Identificação de cores em objetos em movimento, nesse caso, faixas coloridas presentes no cavalo. (a) Vídeo Origina, (b) Vídeo Processado.	96

LISTA DE TABELAS

Tabela 1 - Quantidade de objetos por classe utilizado para treinamento e teste e quantidade total após a rotação de cada objeto.	73
Tabela 2 - Matriz de Confusão para o classificador SVM + HOG treinado. A linha diagonal formada indica as amostras classificadas corretamente.	75
Tabela 3 - Desempenho do classificador treinado para cada classe e desempenho total do classificador SVM com características HOG dos objetos.	75
Tabela 4 - Tempo de processamento pela CPU de cada etapa e total de um frame de vídeo. Na tabela, "s" significa segundos.	81
Tabela 5 - Tempo de processamento de cada etapa e total no ortomosaico apresentado na Figura 26 (c). Na tabela, "s" significa segundos.	81
Tabela 6 - Tempo de processamento de um frame utilizando a GPU.	82

LISTA DE ABREVIATURAS

ANAC	Agência Nacional de Aviação Civil
ANATEL	Agência Nacional de Telecomunicações
ANTT	Agência Nacional de Transportes Terrestres
CNT	Confederação Nacional do Transporte
DECEA	Departamento de Controle do Espaço Aéreo
DNIT	Departamento Nacional de Infraestrutura e Transporte
ES	Elemento Estruturante
HOG	<i>Histogram of Oriented Gradient</i>
HSB	<i>Hue-Saturation-Brightness</i>
HSI	<i>Hue-Saturation-Intensity</i>
HSV	<i>Hue-Saturation-Value</i>
ISODATA	<i>Iterative Self-Organizing Data Analysis Technique</i>
PCA	<i>Principal Componente Analysis</i>
PDI	Processamento Digital de Imagens
RBAC-E	Regulamento Brasileiro de Aviação Civil Especial
RDT	Recursos de Desenvolvimento Tecnológico
RGB	<i>Red-Green-Blue</i>
ROI	<i>Region of Interest</i>
RPAS	<i>Remotely-Piloted Aircraft System</i>
SARPAS	Sistema de Autorização de Acesso ao Espaço Aéreo por RPAS
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i>
UTFPR	Universidade Tecnológica Federal do Paraná
VANT	Veículo Aéreo Não Tripulado

LISTA DE SÍMBOLOS

\wedge	“E” lógico
\circ	Operação morfológica de abertura
\oplus	Operação morfológica de dilatação
\ominus	Operação morfológica de erosão
\bullet	Operação morfológica de fechamento
α	Direção do gradiente
B	Canal azul no sistema RGB
C_b	Diferença entre o brilho e componente azul no sistema de cores YC_bC_r
C_r	Diferença entre o brilho e componente vermelho no sistema de cores YC_bC_r
d_k	Direção da borda
f_s	Imagem suavizada
G	Canal verde no sistema de cores RGB
g_N	Imagem de supressão de não máximos
g_{NL}	Imagem resultante do limiar inferior do algoritmo de Canny
g_{NH}	Imagem resultante do limiar superior do algoritmo de Canny
g_x	Derivada parcial da imagem em x
g_y	Derivada parcial da imagem em y
m	Valor mínimo de cada canal RGB
M_G	Magnitude do gradiente
R	Canal vermelho no sistema de cores RGB
H	Canal de matiz do sistema de cores HSV
S	Canal de saturação do sistema de cores HSV
T_L	Limiar inferior do algoritmo de Canny
T_H	Limiar superior do algoritmo de Canny
V	Canal de valor (ou brilho) do sistema de cores HSV
Y	Brilho da Imagem no sistema de cores YC_bC_r
σ	Desvio padrão
n	Número de pixels

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	CONSIDERAÇÕES INICIAIS	16
1.2	OBJETIVOS.....	19
1.2.1	OBJETIVOS GERAIS	19
1.2.2	OBJETIVOS ESPECÍFICOS	20
1.3	JUSTIFICATIVA	20
1.4	ESTRUTURA DO TRABALHO	21
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	SENSORIAMENTO REMOTO E MONITORAMENTO DE RODOVIAS	23
2.1.1	INSPEÇÃO POR VEÍCULO VIA TERRESTRE.....	23
2.1.2	INSPEÇÃO POR SATÉLITE	25
2.1.3	INSPEÇÃO POR VANT.....	25
2.2	ESTRUTURA DE RODOVIAS.....	26
2.3	SEGMENTAÇÃO DE RODOVIAS EM IMAGENS DE SENSORIAMENTO REMOTO	27
2.4	IDENTIFICAÇÃO DE MARCAÇÕES HORIZONTAIS	28
2.5	TÉCNICAS DE PDI.....	33
2.5.1	REPRESENTAÇÃO DE IMAGENS	33
2.5.2	SEGMENTAÇÃO	37
2.5.2.1	Segmentação por Cores.....	38
2.5.2.2	Identificação de Bordas.....	40
2.5.3	FILTRO ESPACIAL DE SUAUIZAÇÃO	43
2.5.4	OPERAÇÕES EM IMAGENS BINÁRIAS.....	44
2.5.4.1	Operações Morfológicas	44
2.5.4.2	Contornos.....	47
2.6	CLASSIFICAÇÃO	48
2.6.1	HISTOGRAMA ORIENTADO AO GRADIENTE.....	48
2.6.2	SVM	49
3	MATERIAIS E MÉTODOS	52
3.1	ESPECIFICAÇÕES DO VANT E DA CÂMERA	52
3.2	SISTEMA DE NAVEGAÇÃO DO VANT	53

3.3	GERAÇÃO DE ORTOMOSAICO	54
3.4	SISTEMA COMPUTACIONAL	56
3.5	PROCEDIMENTOS PARA AQUISIÇÃO E PROCESSAMENTO DE IMAGENS 56	
3.6	PRÉ-PROCESSAMENTO	58
3.7	SEGMENTAÇÃO DE OBJETOS	63
3.8	CLASSIFICAÇÃO DE OBJETOS	66
4	RESULTADOS E DISCUSSÕES	68
4.1	TESTES DE SEGMENTAÇÃO DE OBJETOS	68
4.1.1	TESTES EM AMBIENTE CONTROLADO.....	69
4.1.2	TESTE EM AMBIENTE REAL	71
4.2	TREINAMENTO E TESTE DO SVM	73
4.3	TESTES COM O ALGORITMO DESENVOLVIDO	76
4.4	TESTES de tempo de resposta	80
5	CONCLUSÃO E TRABALHOS FUTUROS	83
5.1	TRABALHOS FUTUROS	86
	REFERÊNCIAS	88
	APÊNDICE A – CHECKLIST DE VOO	94
	APÊNDICE B – SEGMENTAÇÃO POR CORES DE OBJETOS EM MOVIMENTO	95

1 INTRODUÇÃO

Este capítulo contém a introdução do trabalho com suas considerações iniciais, objetivos, justificativas e estrutura.

1.1 CONSIDERAÇÕES INICIAIS

O Brasil possui uma malha rodoviária com 1.720.756 km, sendo essa a via mais utilizada para locomoção no país, representando uma participação de 61,1% da movimentação anual de cargas e passageiros (CONFEDERAÇÃO NACIONAL DO TRANSPORTE, 2017). Entretanto, somente 12,3% dessa malha é pavimentada. Além disso, em pesquisa realizada pela Confederação Nacional do Transporte (CNT) em 2016, onde foram analisados 103.259 km de rodovias estaduais e federais pavimentadas, 58,2% apresentam algum problema. Estes problemas são encontrados no pavimento, sinalização ou geometria da via, como pode ser visualizado na Figura 1 que apresenta o estado geral, condição do pavimento, sinalização e geometria da via das rodovias no Brasil. (CONFEDERAÇÃO NACIONAL DO TRANSPORTE; SERVIÇO SOCIAL DO TRANSPORTE; SERVIÇO NACIONAL DE APRENDIZAGEM DO TRANSPORTE, 2016).




Figura 1 - Condições das rodovias pavimentadas no Brasil.

Fonte: Adaptado de Confederação Nacional do Transporte, Serviço Social do Transporte, Serviço Nacional De Aprendizagem do Transporte (2016, p. 72).

Referente ao pavimento, 69,3% apresentaram algum problema, sendo que 48,3% são problemas de desgaste e 17,3% problemas de trincas no pavimento. No quesito sinalização horizontal, 35,8% das faixas centrais foram encontradas em estado desgastado e 6,2% não estavam

mais presentes no pavimento. As condições da faixa lateral apresentaram pintura desgastada em 34% e inexistente em 13,9% das rodovias analisadas (CONFEDERAÇÃO NACIONAL DO TRANSPORTE; SERVIÇO SOCIAL DO TRANSPORTE; SERVIÇO NACIONAL DE APRENDIZAGEM DO TRANSPORTE, 2016).

Devido à má condição de circulação da malha rodoviária brasileira, o custo operacional de transporte de cargas pode ter um aumento entre 24,9% e 91,5%, dependendo da condição da rodovia. Estes custos podem ser incrementados devido ao gasto desnecessário de combustível e troca precoce de peças e pneus. Estes desgastam com maior facilidade devido ao esforço excessivo causado pela má condição da via. Além desse problema, o mau estado das vias rodoviárias causam vários acidentes, gerando alto custo ao governo (CONFEDERAÇÃO NACIONAL DO TRANSPORTE; SERVIÇO SOCIAL DO TRANSPORTE; SERVIÇO NACIONAL DE APRENDIZAGEM DO TRANSPORTE, 2016).

A manutenção de estradas de rodagem, além de custosa, necessita o deslocamento prévio de técnicos para avaliar o ambiente e definir os pontos a serem reparados. Esta análise, na maioria das vezes, é efetuada *in situ* de forma manual com interpretação visual de informações. Entre outras desvantagens dessa técnica, destacam-se os riscos ao operador, grande tempo de operação, baixa reprodutibilidade, alto custo, pequena área de abrangência entre outros problemas gerados pela análise visual (CHAMBON; MOLIARD, 2011; GAVILÁN *et al.*, 2011; JAHANSHAHI *et al.*, 2013; ZAKERI; NEJAD; FAHIMIFAR, 2016). No entanto, já existem órgãos que estão empregando técnicas automáticas ou semiautomáticas no monitoramento da estrutura da rodovia, diminuindo custos e tempo de execução na verificação do estado atual da malha rodoviária, além de melhorar a precisão das informações coletadas (JAHANSHAHI *et al.*, 2013; SCHNEBELE *et al.*, 2015).

Perante informações sobre a malha rodoviária do país e desvantagens da análise manual, imagens de rodovias, em conjunto com a aplicação de processamento digital de imagens (PDI) e visão computacional, oferecem monitoramento preciso, ou seja, com maior nível de detalhes. Além disso, o processo de aquisição de informações é efetuado em menor tempo e com maior abrangência na análise do estado atual das rodovias (CHAMBON; MOLIARD, 2011; SCHNEBELE *et al.*, 2015).

No monitoramento de rodovias, uma abordagem que pode ser utilizada é o sensoriamento remoto (SR). Este consiste de técnicas que, durante a obtenção das informações da via, não entram em contato físico como, por exemplo, o uso de satélites com câmeras de espectro visível e infravermelho para obter informações ou uma câmera fixada em um veículo. Dentre as técnicas de

aquisição em sensoriamento remoto, a utilização do espectro visível é uma opção amplamente utilizada (SCHNEBELE *et al.*, 2015).

Uma das abordagens para efetuar a aquisição de informações da rodovia é o uso de veículos com câmeras acopladas, que captam informações do pavimento e seus componentes (CHAMBON; MOLIARD, 2011; KADDAH *et al.*, 2016). Outra técnica é utilizar imagens aéreas de rodovias que podem fornecer informações mais abrangentes, sendo essas adquiridas por satélites ou aeronaves (WANG *et al.*, 2016; ZHOU *et al.*, 2016).

O uso de imagens aéreas de rodovias permite adquirir várias informações que possibilitam a análise mais detalhada da região de localização da rodovia. Grande parte dessas imagens são obtidas através de satélites. Imagens aéreas podem ser utilizadas em sistemas de monitoramento remoto de cidades, mapeamento geográfico, monitoramento e avaliação ambiental entre outras aplicações (WANG *et al.*, 2016). Alguns trabalhos, além de utilizar imagens de satélite no espectro visível para análise do pavimento, utilizam imagens hiperspectrais e infravermelho em conjunto com informações de sinais obtidos pela propagação de lasers em comprimentos de ondas específicos (SCHNEBELE *et al.*, 2015).

Outra tecnologia que está sendo aplicada na obtenção de imagens aéreas no espectro visível, com maior flexibilidade do local a ser analisado, é o uso de Veículo Aéreo Não Tripulado (VANT) com câmera acoplada (COLOMINA; MOLINA, 2014; FENG; YUNDONG; QIANG, 2009; ZAKERI; NEJAD; FAHIMIFAR, 2016; ZHOU *et al.*, 2015). O uso dessa tecnologia tem aumentado não somente no campo de pesquisa, mas também na indústria e, principalmente, pela agricultura de precisão, devido a sua versatilidade (DAY; WEAVER; WILSON, 2016; HEIPKE *et al.*, 2016).

Através de imagens aéreas, podem ser efetuadas a análise de tráfego, planejamento de cidades, monitoramento de rodovias, atualização de mapas, entre outras análises (WANG *et al.*, 2016). A extração de características da rodovia contida na imagem aérea é efetuada com o emprego de técnicas de PDI. Estas técnicas tem sido amplamente estudadas com o propósito de reduzir tempo de processamento e obter resultados com informações mais precisas do ambiente monitorado através de imagens (CHOPADE; GURU, 2015; JIN; FENG, 2010; WANG *et al.*, 2016; ZAKERI; NEJAD; FAHIMIFAR, 2016; ZHOU *et al.*, 2016).

Com o aumento no uso de VANT em várias aplicações, órgãos reguladores do espaço aéreo estão desenvolvendo regulamentos específicos para a operação desse tipo de aeronave (COLOMINA; MOLINA, 2014). No Brasil, o uso comercial de VANT foi regulamentado em 2017 pela Agência Nacional de Aviação Civil (ANAC) através do Regulamento Brasileiro de Aviação

Civil Especial nº 94 (RBAC-E nº 94), intitulado “Requisitos Gerais para Aeronaves Não tripuladas de uso Civil” (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2017a) e suas respectivas instruções suplementares (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2017b). A RBAC-E nº 94 é a principal regra vigente, que deve ser cumprida em todos os voos executados por essa classe de aeronaves.

Como toda aeronave remotamente pilotada possui um sistema de transmissão de informações, a Agência Nacional de Telecomunicações (ANATEL) possui regra que exige a homologação dos sistemas de rádio frequência para operação do VANT (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2017b; PORTAL BRASIL, 2017). Além da regulamentação, o Departamento de Controle do Espaço Aéreo (DECEA) iniciou em dezembro de 2016 a operação do sistema de solicitação de acesso ao espaço aéreo de Sistema de Aeronave Remotamente Pilotada – *Remotely-Piloted Aircraft System* (RPAS) intitulado Sistema de Autorização de Acesso ao Espaço Aéreo por RPAS (SARPAS). Para utilizar o sistema, o piloto deve efetuar o seu cadastro e o da aeronave. Com os cadastros aprovados é possível solicitar o espaço aéreo e efetuar voos com VANT (DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO, 2016).

Diante das informações apresentadas, o uso de VANT com câmera acoplada pode proporcionar o monitoramento remoto de rodovias de forma rápida e com maior área de abrangência. Em conjunto com o uso desse tipo de aeronave, é possível utilizar técnicas de PDI para que informações detalhadas sejam extraídas das imagens aéreas adquiridas de rodovias. Entretanto, na execução de missões de aquisição de imagens, deve-se atentar às regras aeronáuticas vigentes para as RPAS, para que os voos sejam executados em segurança e obedecendo as regras.

1.2 OBJETIVOS

1.2.1 OBJETIVOS GERAIS

Através do conhecimento dos problemas da malha rodoviária brasileira e devido as vantagens de analisar a estrutura da rodovia através de imagens aéreas, esta dissertação tem como objetivo principal desenvolver uma metodologia para monitorar rodovias através de imagens adquiridas por VANT. A metodologia será desenvolvida em conjunto com a concessionária de rodovias Triunfo Concebra a partir do programa de Recursos de Desenvolvimento Tecnológico (RDT) da ANTT, financiadora deste projeto. A concessionária definirá os pontos de interesse a serem monitorados. A partir desta informação, técnicas de PDI serão aplicadas para que estes

pontos sejam extraídos e classificados por métodos de reconhecimento de padrões, permitindo análise ágil e detalhada de uma rodovia que será monitorada pela metodologia desenvolvida.

1.2.2 OBJETIVOS ESPECÍFICOS

Definido o objeto principal, os seguintes objetivos específicos compõem o trabalho:

- 1) Efetuar o desenvolvimento de procedimentos para aquisição das informações, incluindo planejamento do voo, solicitação de espaço aéreo e *check-list* de execução de voo;
- 2) Desenvolver algoritmo que utilizará técnicas de PDI para segmentar a rodovia da imagem adquirida, possibilitando a análise pontual da rodovia e seus componentes, como marcações horizontais;
- 3) Desenvolver algoritmo que, a partir da imagem que contenha somente a rodovia, aplique técnicas para encontrar objetos através de suas bordas, sendo os principais objetos de interesse, traços, setas, escritas, carros e defeitos no pavimento, segmentando e extraindo características para sua posterior classificação;
- 4) Utilizar de técnicas de reconhecimento de padrões para classificar objetos segmentados através de suas características extraídas;
- 5) Apresentar as informações coletadas a partir das imagens de maneira visual, marcando cada objeto com uma cor que represente a sua classe.

1.3 JUSTIFICATIVA

Grande parte dos trabalhos desenvolvidos com o uso de imagens aéreas de rodovias preocupam-se em extrair a rodovia da imagem (WANG *et al.*, 2016; ZHOU *et al.*, 2016) ou em analisar rachaduras na pista (SCHNEBELE *et al.*, 2015; ZAKERI; NEJAD; FAHIMIFAR, 2016). Porém, para o monitoramento de rodovias, somente essas informações não são suficientes para analisar o estado de conservação da via. Outras informações sobre a rodovia também devem ser analisadas como, por exemplo, sinalizações de trânsito, o que inclui as marcações horizontais. Estas marcações possuem informações importantes da via que orientam o deslocamento do

motorista pela via, além de fornecer segurança ao usuário (JIN; FENG, 2010; LIN; WU; WANG, 2016; NODA; KOJIMA, 2009).

A partir de imagens aéreas e a aplicação de técnicas de PDI, é possível extrair objetos presentes na rodovia que podem proporcionar uma análise mais abrangente da conservação da via. A extração de objetos dentro da rodovia pode proporcionar, além da análise da estrutura da rodovia, a análise de tráfego da estrada informando acidentes e pontos de congestionamento (WEI *et al.*, 2016). Já existem trabalhos propondo monitoramento contínuo da rodovia através de RPAS, que informará os veículos, que estão trafegando pela via, sobre problemas no pavimento e informações do fluxo da rodovia (CHEN; DONG; OH, 2007; MENOVAR *et al.*, 2017; RO; OH; DONG, 2007).

Devido a necessidade de efetuar manutenções de rotina e preventivas no pavimento rodoviário, o uso de VANT permite maior flexibilidade na aquisição das informações. Assim, é possível ser definido, em detalhes, pontos específicos a serem monitorados, além de proporcionar um acompanhamento detalhado dos pontos monitorados.

As imagens coletadas em conjunto das técnicas de PDI e reconhecimento de padrões, podem oferecer informações que não foram notadas pelo especialista no momento de análise *in situ*. Através do uso dessas ferramentas é possível desenvolver uma abordagem que forneça as informações de forma automática, diminuindo o deslocamento de funcionários e custos com análises *in loco* dos pontos de interesse, além de permitir a revisão de pontos específicos.

1.4 ESTRUTURA DO TRABALHO

O capítulo 2 apresenta a fundamentação teórica utilizada no trabalho desenvolvido e uma breve revisão do estado da arte. No capítulo 3 é descrito em detalhes os materiais e métodos utilizados para o desenvolvimento do algoritmo de processamento de imagens. No capítulo 4, os resultados obtidos são apresentados e discutidos com a intenção de verificar a eficácia da metodologia proposta. O capítulo 5 apresenta as conclusões do desenvolvimento deste trabalho e possíveis trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será apresentado o embasamento teórico para o desenvolvimento do trabalho, os métodos utilizados no monitoramento de rodovias através de imagens e as técnicas de PDI empregadas por esses métodos.

No momento atual as informações sobre a rodovia são adquiridas de maneira visual. Sua análise também é realizada de forma manual e devido a isto, problemas de inconsistência de dados podem ser gerados. Diante desse problema outras técnicas para adquirir informações de rodovias foram sendo desenvolvidas ao longo dos anos. Uma destas técnicas para adquirir tais informações é o uso de sensoriamento remoto (SR). Assim, na seção 2.1 deste capítulo, é apresentado uma breve revisão sobre metodologias para monitoramento de rodovias através de sensoriamento remoto.

Através da aquisição de imagens de rodovia por métodos de SR, outras informações além da rodovia podem estar presentes na imagem. Então, é necessário efetuar a segmentação da rodovia dessas imagens para que somente esta seja processada, e não a imagem como um todo. Desta forma, a seção 2.2 do presente capítulo apresenta um modelo e as características das rodovias em imagens aéreas de SR. A partir do modelo, a seção 2.3 fornece técnicas que podem ser utilizadas para segmentar a rodovia de imagens de SR.

Com a imagem da rodovia segmentada, outras informações da estrada podem ser extraídas. Uma desta é a marcação horizontal. Desta forma a seção 2.4 desse capítulo apresenta maneiras de extrair essas informações e um trabalho que efetua a segmentação da rodovia e das marcações horizontais de imagens aéreas.

Após a revisão de métodos e trabalhos que analisam imagens aéreas de rodovias, a seção 2.5 apresenta técnicas de PDI que são utilizadas para segmentar a rodovia da imagem e objetos como, por exemplo, as marcações horizontais. Como se deseja classificar os objetos segmentados, a seção 2.6 apresenta uma técnica para extrair características dos objetos segmentados e um método de reconhecimento de padrões para classificar os objetos segmentados.

2.1 SENSORIAMENTO REMOTO E MONITORAMENTO DE RODOVIAS

Dentre várias técnicas para monitorar rodovias, o SR está sendo amplamente empregado para executar esta tarefa. Schnebele *et al.* (2015) desenvolveram uma análise das metodologias que utilizam sensoriamento remoto para avaliar e gerenciar pavimentos. De acordo com Schnebele *et al.* sensoriamento remoto é “qualquer método de levantamento de resultados que não requer contato físico com a superfície ou abaixo da superfície da estrada” (SCHNEBELE *et al.*, 2015, p. 2). Com esta definição a utilização de câmeras fotográficas é um tipo de sensoriamento remoto, pois não necessita contato físico com a superfície a ser monitorada. Porém, para adquirir as imagens é necessária uma plataforma de fixação da câmera. As principais plataformas utilizadas no monitoramento de rodovias por imagens são: veículos, satélites e VANT. A principal vantagem do uso de sensoriamento remoto para monitorar rodovias é a possibilidade de obter informações sem a necessidade de interromper o tráfego da via (SCHNEBELE *et al.*, 2015).

2.1.1 INSPEÇÃO POR VEÍCULO VIA TERRESTRE

Este tipo de inspeção utiliza um veículo, que percorre a via a ser monitorada, equipado com câmeras e conjunto de sensores que fornecem informações como textura e rachaduras do pavimento (CHAMBON; MOLIARD, 2011; SCHNEBELE *et al.*, 2015).

Nesta abordagem o veículo percorre a via, adquirindo imagens e informações de outros sensores, como lasers e sistemas de geolocalização de uma seção da rodovia. Ao final da aquisição essas imagens podem ou não serem unidas. Na sequência, as imagens são submetidas a análises através de PDI com a finalidade de verificar a condição do pavimento. A partir dos resultados obtidos é possível encontrar pontos de desgaste, sendo grande parte da pesquisa em métodos para monitoramento de rodovias por veículos estar focada na obtenção de imagens para análise da estrutura do pavimento (CHAMBON; MOLIARD, 2011; SCHNEBELE *et al.*, 2015). Uma técnica de PDI utilizada na verificação de pavimento é aplicação de detectores de borda, como o de Sobel ou Canny que permite analisar o pavimento e encontrar eventuais fissuras (MOHAN; POOBAL, 2017). Um exemplo de veículo e o sistema para monitorar as imagens pode ser visualizado na Figura 2.

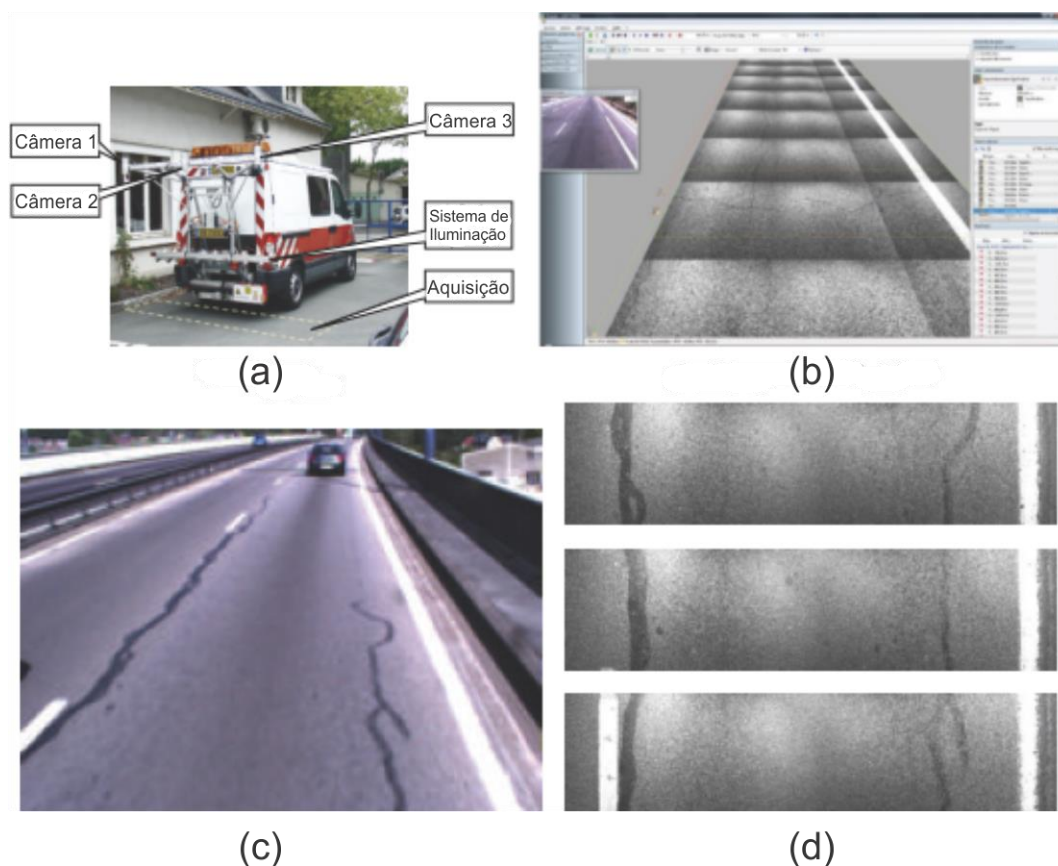


Figura 2 - Exemplo de sistema de inspeção veicular de asfalto. (a) veículo instrumentado, (b) Interface homem máquina, (c) Imagens do ambiente a ser monitorado, (d) Imagens processadas.

Fonte: Adaptado de Chambon; Moliard, (2011, p. 8).

A principal vantagem dessa técnica é a possibilidade de monitorar ambientes abaixo de pontes e locais arborizados, sendo estes ambientes um impedimento para análise a partir de imagens aéreas (SCHNEBELE *et al.*, 2015). O monitoramento nestes locais tem um agravante que é a presença de sombras, o que pode dificultar a análise. Isto acontece pelo fato de vários algoritmos utilizarem técnicas que analisam o contraste para identificar objetos. Assim, um local com sombra pode ser identificado como um objeto, fornecendo uma resposta errada (WEI ZHANG *et al.*, 2007). Outra vantagem é a possibilidade de posicionar a câmera em ângulo de 90° em relação a estrada, adquirindo somente o ponto de interesse, a rodovia, diminuindo desta maneira a quantidade de procedimentos necessário para análise. Além disso, pelo fato da câmera estar muito próxima ao pavimento o nível de detalhamento é elevado. A principal desvantagem dessa técnica é a pequena área adquirida e a necessidade de adquirir uma faixa por vez. Como o veículo instrumentado precisa trafegar pela via para adquirir informações, devido ao fluxo de veículos em outras faixas da estrada, estes veículos podem obstruir a aquisição de trechos da rodovia, dificultando assim a análise do pavimento.

2.1.2 INSPEÇÃO POR SATÉLITE

Diferente da inspeção veicular, o uso de imagens obtidas por satélite permite a visualização de grandes áreas em uma imagem. Imagens de satélite em alta resolução são utilizadas para extrair vários aspectos de rodovias. Antes de extrair informações referente a rodovia das imagens, devido à grande área de abrangência, muitas informações além da estrada são adquiridas. Então é necessário primeiro segmentar a rodovia da imagem. Esse procedimento é efetuado para que somente a rodovia seja analisada (WANG *et al.*, 2016). Trabalhos que envolvem o uso de informações de satélite normalmente utilizam outras informações em conjunto com imagens, como câmeras hiperespectrais, propagação de lasers e ondas de rádio para que seja efetuada uma análise mais completa do ambiente a ser monitorado (SCHNEBELE *et al.*, 2015).

Imagens de satélite podem ser uma grande ferramenta para análise de rodovias. Mesmo com a vantagem de abranger grandes áreas em poucas imagens, a principal desvantagem dessa técnica é a obstrução da via por árvores, pontes e veículos. O tempo de atualização das imagens pode ser outro problema, pois mesmo que as condições de marcações e estrutura do pavimento não tenham a necessidade de frequente atualização, a utilização para verificação de desastres naturais, que danificam o pavimento, pode não ser viável através desse método.

2.1.3 INSPEÇÃO POR VANT

Assim como imagens de satélite, a utilização de aeronaves autônomas permite o monitoramento de grandes áreas. A diferença entre as imagens de satélite e as imagens de VANT são a área de abrangência, que varia de acordo com a altura de voo, e a possibilidade de adquirir vídeos das áreas a serem monitoradas. Caso essa altura faça com que a imagem possua outras informações além da rodovia, será necessário, assim como nas imagens de satélite, um pré-processamento para extrair a rodovia da imagem (ZHOU *et al.*, 2016).

Zakeri; Nejad e Fahimifar (2016) desenvolveram um VANT para efetuar a análise do pavimento. Essa aeronave possui autonomia de 45 minutos e pode percorrer uma distância de 7 km a 4 m/s. A câmera acoplada ao sistema é uma GoPro, permitindo fotografias de até 14 Mpixels. O

principal objetivo desse trabalho foi a análise do pavimento, sendo verificado sua estrutura e falhas. Assim, os pesquisadores desenvolveram uma abordagem com três estágios de processamento das imagens adquiridas, utilizando técnicas de PDI e o uso de métodos de reconhecimento de padrões.

Entre as vantagens dessa técnica estão a abrangência de grandes áreas, a utilização de imagens estáticas e vídeos, além da flexibilidade de configurar o nível de detalhe do local a ser monitorado, dependendo da altura do voo. Além disso, o uso de aeronaves com asa rotativa pode ser utilizada para verificar a estrutura de pontes, viadutos e outras estruturas que compõem a rodovia, não se limitando somente ao pavimento. A principal desvantagem dessa técnica é o tempo de voo do VANT de baixo custo, que estão limitados a aproximadamente 45 minutos, além de serem poucos modelos que ofereçam resistência a chuva (COLOMINA; MOLINA, 2014).

2.2 ESTRUTURA DE RODOVIAS

Após adquiridas imagens de estradas a partir de SR, especificamente imagens de satélites e VANT, é necessário compreender como rodovias são representadas nestas imagens. Para melhor compreensão, Wang *et al.* (2016, p. 272) definem que “uma rodovia em imagem de sensoriamento remoto aparece com características geométricas alongadas e com pouca diferença nos valores de cinza”. Além disso, Wang *et al.* definem que a imagem de uma rodovia pode apresentar as seguintes características (Wang *et al.*, 2016, p. 272):

- **Geométricas:** que refere ao formato da rodovia na imagem, sendo na maioria das vezes, linhas longas, e no caso de junções de vias, podendo apresentar formatos em “T”, “Y”, “+” entre outros formatos;
- **Fotométricas:** informações sobre as cores da rodovia, ou informações de radiação. Essa característica é que indicará qual parte é a rodovia e qual parte são construções ou vegetação;
- **Topológicas:** são referentes ao formato da rodovia, sendo que uma rodovia é contínua e sem interrupções;
- **Funcionais:** são condições necessárias que possibilitem o tráfego de veículos em uma rodovia;

- **Textura:** diferentes partes da rodovia podem possuir texturas diferentes como, por exemplo, partes com pavimento novo ou locais com partes mais desgastadas que podem apresentar variações nas colorações dos pixels.

Além dessas características Baumgartner *et al.* (1999) propuseram um modelo de como uma rodovia é representada em uma imagem de sensoriamento remoto. Este modelo, em conjunto com as características descritas, facilita o entendimento de como a rodovia e seus componentes são apresentados em imagem aérea. A Figura 3 apresenta o modelo proposto por Baumgartner e colaboradores.

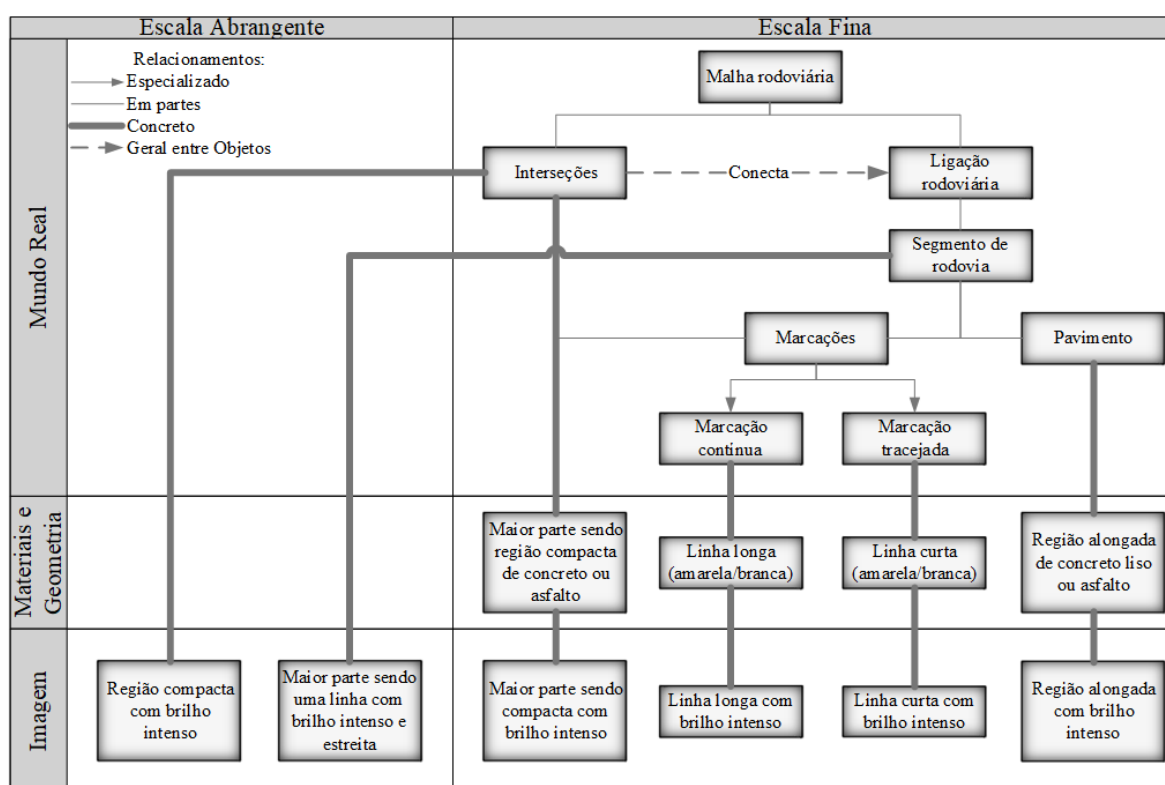


Figura 3 - Modelo de uma rodovia em imagens aéreas de SR. Esse modelo apresenta características da rodovia como um todo (escala abrangente) e de seus componentes (escala fina). Cada bloco do modelo apresenta uma característica da rodovia.

Fonte: Adaptado de Baumgartner *et al.*, (1999, p. 779)

2.3 SEGMENTAÇÃO DE RODOVIAS EM IMAGENS DE SENSORIAMENTO REMOTO

Imagens de alta resolução de SR aéreas possuem várias informações além da rodovia. Nesse aspecto é necessário que a rodovia seja extraída da imagem a fim de fazer as análises

desejadas somente nos pixels que contenham segmentos de rodovia. Pelo fato de rodovias serem a principal via para tráfego de veículos de muitos países, vários trabalhos estão sendo desenvolvidos para que sejam extraídas rodovias em imagens de SR (WANG *et al.*, 2016).

A partir das características de imagens de SR que possuem rodovias, Wang *et al.*, (2016) desenvolveram um trabalho de análise dos métodos de extração de rodovias em imagens de SR com alta resolução. O trabalho de Wang *et al.*, (2016) menciona várias técnicas que podem ser utilizadas para extrair rodovias em imagens de SR. Os métodos podem ser baseados em classificação supervisionada e não supervisionada, utilização de morfologia matemática, análise de contornos e programação dinâmica e agrupamento, onde cada método possui suas particularidades. Entretanto, imagens de satélite possuem maior tempo para serem atualizadas. Diante desse problema, RPAS podem oferecer atualização de ambientes com menor espaço de tempo, além da possibilidade de adquirir informações de locais específicos. Outras vantagens do uso de RPAS são suas imagens, na maioria dos casos, serem georeferenciadas permitindo análise mais completa do ambiente monitorado. Com a versatilidade do VANT em efetuar voos entre baixa e média altitude, assim como nas imagens de satélite, mais informações além da rodovia podem ser adquiridas (ZHOU *et al.*, 2016).

Vários trabalhos veem sendo desenvolvidos no âmbito de segmentar rodovias de imagens adquiridas a partir de VANT. Como essas imagens, quando adquiridas com câmera posicionada a 90° em relação ao solo, se assemelham com imagens de satélite, alguns trabalhos utilizam técnicas similares para segmentação de rodovias, enquanto outros utilizam diferentes técnicas com o objetivo de obter resultado semelhante (CHOPADE; GURU, 2015).

2.4 IDENTIFICAÇÃO DE MARCAÇÕES HORIZONTAIS

Com o crescimento das pesquisas nas áreas de carros autônomos, sistemas de dirigibilidade assistida e realidade aumentada, vários trabalhos veem sendo desenvolvidos para identificar marcações horizontais em rodovias. Estes são utilizados pelos sistemas indicando atitudes a serem tomadas (VEIT *et al.*, 2008). Pelo fato de marcações sob a rodovia estarem sujeitas a desgaste com o tempo, já existem trabalhos preocupados em utilizar sistemas de inteligência artificial que reconhecem marcações defeituosas por carros autônomos (VOKHIDOV *et al.*, 2016).

Devido a importância das marcações horizontais, tanto para sistemas autônomos como para motoristas e pedestres, Lin, Wu e Wang (2016) desenvolveram uma metodologia para avaliar

sua qualidade. As imagens são adquiridas a uma altura de 120 cm em 90° com a marcação. Adquirida a imagem, esta é pré-processada e logo após é efetuada a detecção de borda, sendo aplicado o algoritmo de Canny (LIN; WU; WANG, 2016). Com a borda da marcação é efetuada uma análise geométrica através do desvio padrão da linha da borda identificada pelo detector de Canny. A partir dessa informação é definido se a qualidade de confecção da marcação está dentro de parâmetros definidos. O trabalho presa pela verificação logo após a confecção, pois se na fabricação apresentar baixa qualidade, esta poderá apresentar desgaste precoce, necessitando reparo nessas marcações antes do previsto.

Referente a trabalhos com imagens aéreas, Ishino e Saji (2008) utilizam técnicas de PDI para detectar faixas de pedestre e faixas de tráfego. A detecção da faixa de pedestre é efetuada através de limiarização, emprego de operações morfológicas e seleção de partes segmentadas através de análise de geometria e direção. As faixas de tráfego são detectadas por análise de frequência do histograma através dos picos que são formados e verificar se o pico identificado é ou não um candidato de linha de tráfego e, neste caso, é efetuado a extração dessas linhas. Os pesquisadores obtiveram uma taxa de acerto de 85,3% na extração de faixa de pedestres e 87,4% na extração de linhas de tráfego.

Jin e Feng, (2010) desenvolveram um trabalho em que se utilizou imagens aéreas de baixa e alta resolução para identificar a rodovia e as marcações horizontais. Na primeira etapa desse trabalho, os pesquisadores utilizam transformada discreta Wavelet para gerar uma imagem de baixa resolução e assim extrair a linha central da rodovia. A Figura 4 apresenta um exemplo de imagem de alta e baixa resolução utilizada pelos pesquisadores. Esse procedimento é efetuado construindo uma imagem com três canais, onde o primeiro contém a primeira componente da transformada da análise de componente principal – *Principal Component Analysis* (PCA) da imagem no sistema Vermelho-Azul-Verde – *Red-Green-Blue* (RGB). O resultado da PCA fornece que 96,4% de toda a informação da imagem está contida no canal “*R*” da imagem RGB. O segundo canal é o de saturação “*S*” do sistema de cores Matiz-Saturação-Intensidade – *Hue-Saturation-Intensity* (HSI), pois devido as características da rodovia, ela possui baixo valor de saturação. Pelo fato da imagem apresentar vegetação além da rodovia, e como imagens RGB apresentam baixo valor do componente azul, é necessário um método para distinguir vegetação de área pavimentada. Então, a imagem é convertida do sistema RGB para YC_bC_r , onde o canal “*C_b*” apresenta a diferença entre o brilho da imagem e o canal azul do sistema RGB, distinguindo assim,

vegetação de pavimento. Assim, o terceiro canal da imagem é formado pelo componente “ C_b ”. A Figura 5 apresenta cada componente extraído e a imagem resultante.



Figura 4 - Imagem de exemplo. (a) Imagem de alta resolução, (b) Imagem de baixa resolução.

Fonte: Jin e Feng, (2010, p. 338)




Figura 5 – Formação de nova imagem a partir de informações em diferentes espaços de cores da imagem original. A imagem apresenta três bandas de cores transferidas da imagem original onde (a) apresenta a 1ª componente da transformada PCA, (b) canal de saturação do espaço de cores HSI, (c) componente C_b do espaço de cores YC_bC_r e (d) resultado da composição das três imagens.

Fonte: Jin e Feng, (2010, p. 339).

A partir da imagem constituída dos três componentes distintos é utilizado o algoritmo de segmentação não supervisionado *Iterative Self-Organizing Data Analysis Technique* (ISODATA) para encontrar a linha central da rodovia na imagem de baixa resolução, onde são definidas três

classes: regiões de estrada, vegetação e sombras. Após a segmentação é efetuado uma verificação na geometria do segmento de rodovia encontrado na imagem. Duas condições da geometria devem ser satisfeitas: a média da largura do segmento deve estar em uma faixa pré-definida e a proporção entre largura e altura do segmento deve ser maior que um limiar definido. Assim é encontrado a linha central que serve de base para encontrar a rodovia na imagem de alta resolução.

Com a imagem de alta resolução e utilizando dessa vez somente o canal “ C_b ” do sistema de cores YC_bC_r , pelo mesmo princípio de sua utilização na imagem de baixa resolução, é efetuado o aprimoramento no contraste da imagem formada pelo canal “ C_b ”. Então é aplicado o algoritmo de Otsu (GONZALEZ; WOODS, 2010) para fazer a segmentação da rodovia da imagem. Segmentada a rodovia, são utilizadas as mesmas verificações de geometria com o objetivo de confirmar se o segmento encontrado é ou não uma rodovia. Como podem ocorrer erros, é aplicado um filtro de área para remover pequenos ruídos. Finalmente, emprega-se suavização nas duas laterais do segmento identificado através de uma aproximação linear, utilizando o método dos mínimos quadrados. A Figura 6 demonstra o resultado obtido com a execução dessa fase do algoritmo.




Figura 6 - Segmentação não supervisionada da imagem. (a) apresenta o componente “ C_b ” com contraste aprimorado, (b) o resultado da segmentação, (c) a superfície de rodovia segmentada e (d) as laterais da rodovia suavizadas.

Fonte: Jin e Feng, (2010, p. 340).

A extração das marcações horizontais inicia-se com a aplicação de um filtro Gaussiano anisotrópico (JIN; FENG, 2010). Para melhorar o tempo de processamento é utilizado somente a primeira componente da transformada PCA, assim como executado no primeiro passo. Após a filtragem, já que as marcações possuem brilho mais intenso que o pavimento, estas apresentam maior destaque na imagem. Assim, é efetuado uma análise na geometria desses objetos com brilho intenso, como orientação, largura e tamanho. Caso sejam classificados como marcações, são gravados em uma imagem. Por fim, é gerado uma imagem com a rodovia e suas marcações. O resultado pode ser visualizado na Figura 7.




Figura 7 - Detecção de marcações horizontais, onde (a) apresenta a 1ª componente da transformada PCA da imagem original, (b) o resultado do filtro anisotrópico Gaussiano, (c) as marcações extraídas e (d) as marcações geradas e sobrepostas na rodovia extraída.

Fonte: Jin e Feng, (2010, p. 340)

O método desenvolvido por Jin e Feng foi testado em 8 imagens, cada uma contendo aproximadamente 2 km², sendo obtido uma taxa de detecção de marcações de 97,8%, provando a eficiência da técnica desenvolvida.

2.5 TÉCNICAS DE PDI

A partir do modelo de rodovia apresentado na seção 2.4, e trabalhos relacionados com o objetivo deste trabalho é possível analisar quais ferramentas de PDI podem ser utilizadas no desenvolvimento da metodologia. Então, na seção atual, serão discutidas estas técnicas, apresentando o funcionamento de cada uma.

2.5.1 REPRESENTAÇÃO DE IMAGENS

Uma imagem digital pode ser representada em vários espaços de cores. Alguns podem fornecer informações mais detalhadas que outros sobre pontos específicos da imagem ou simplificar a análise da imagem. Neste trabalho serão utilizadas imagens em escala de cores, em escala de cinza e preto e branco (binárias).

As imagens em cores possuem canais que ao serem unidos formam uma cor única. Assim, existem modelos de como representar essas cores. O sistema de cores amplamente utilizado em dispositivos digitais é o RGB.

No modelo RGB, encontrado na maioria das câmeras digitais, as cores são formadas a partir da mistura do vermelho, do verde e do azul. Este sistema também serve de base na alteração para outros espaços de cores. Porém, a análise de cores específicas pode ser complexa, pois a alteração no valor de um dos canais implica em alterações conjuntas nos demais canais. Isso pode ser visualizado na Figura 8 que apresenta como o espaço de cores RGB pode ser representado e como é atribuído uma cor a um pixel RGB (BEYERER; PUENTE LEÓN; FRESE, 2016a).




Figura 8 - Espaço de cores RGB. O cubo (a) apresenta as tonalidades de cores mais escuras, (b) as tonalidade mais claras e (c) apresenta como o valor de um pixel é representado nesse espaço de cores.

Fonte: Modificado de https://commons.wikimedia.org/wiki/File:RGB_color_cube.svg.

Diante dessa característica é necessário encontrar alternativas para verificar cores específicas, com menor complexidade ou extração de informações específicas sobre as cores. A partir do trabalho desenvolvido por Jin e Feng (2010), dois espaços de cores que podem fornecer uma análise detalhada de imagens aéreas de rodovia são o espaço de cores YC_bC_r e o espaço de cores HSI. Neste trabalho, será utilizado o espaço de cores HSV que se assemelha ao espaço HSI.

2.5.1.1.1 Modelo de cores YC_bC_r

Para transmissões de televisão foram desenvolvidos sistemas de codificação de imagens baseados na diferença entre as cores. O espaço de cores YC_bC_r é um tipo de codificação de imagens digitais. De forma resumida, esse modelo de cores é formado pela diferença entre o brilho da imagem e os canais “ B ” e “ R ” do espaço RGB. A Figura 9 apresenta como esse modelo de cores pode ser representado. A componente “ Y ” representa o brilho na imagem e sua conversão do sistema RGB é obtido através da equação (1) (BEYERER; PUENTE LEÓN; FRESE, 2016a; RUSS; NEAL, 2016a):

$$Y = 0,299R + 0,587G + 0,114B \quad (1)$$

onde as variáveis “ R ”, “ G ” e “ B ” são os componentes vermelho, verde e azul do modelo RGB respectivamente. As coordenadas “ C_b ” e “ C_r ” representam a diferença entre “ Y ” e as componentes “ B ” e “ R ” do sistema RGB. Para obter os valores de “ C_b ” e “ C_r ” a partir da imagem RGB, as equações (2) e (3) são empregadas (BEYERER; PUENTE LEÓN; FRESE, 2016a)

$$C_b = 0,564(B - Y) \quad (2)$$

$$C_r = 0,713(R - Y) \quad (3)$$

Assim como no trabalho desenvolvido por Jin e Feng (2010), o espaço de cores YC_bC_r pode ser utilizado com o propósito de melhorar a identificação de rodovia pavimentada em imagem aérea, utilizando somente o componente “ C_b ”. Isso é possível devido as características do pavimento e do ambiente onde este está localizado, que possui em grande parte de sua extensão, áreas com vegetação. A distinção entre regiões com ou sem pavimento, podem ser melhores distinguidas com as informações da banda “ C_b ”.




Figura 9 - Espaço de cores YC_bC_r . O eixo central Y apresenta a variação do brilho na vertical. Nesta figura o plano inferior possui $Y = 0$, o plano central com $Y = 0,5$ e o plano superior com $Y = 1$. Os componentes C_b e C_r variam na horizontal formando um plano com valores em 0 e 1.

Fonte: Russ e Neal, (2016a, p. 24).

2.5.1.1.2 Modelo de cores HSV

O sistema de cores matiz-saturação-valor – *Hue-Saturation Value* (HSV) (ou HSB, onde “B” representa o brilho (do inglês *brightness*)) representa de maneira mais próxima a forma como os seres humanos discriminam as cores. O sistema HSV representado por um hexacôno e seus valores são obtidos a partir de coordenadas cilíndricas. A Figura 10 demonstra a representação do espaço de cores HSV na forma de cone e a faixa de valores que cada canal pode assumir. O canal “ H ” representa a tonalidade da cor no entorno do cone de cores, variando de 0° a 360° . Já o canal “ S ” define a saturação dessa cor, sendo sua faixa de valor entre 0 e 100 na direção do centro à

borda do cone. Por fim o canal “ V ” define o brilho dessa cor, sendo a variação de 0 a 100 na altura do cone. Como as cores são definidas somente no canal “ H ”, a análise de cores específicas é menos complexa e mais precisa que no espaço RGB (CAPONETTI; CASTELLANO, 2017a).




Figura 10 - Representação do espaço de cores HSV por um cone. Nessa figura, o canal H (*Hue*) representa todo o espaço de cores variando de 0° a 360° . Para apresentar a variação dos canais S (saturação) e V (brilho) o cone está seccionado, sendo possível visualizar o resultado da variação dos parâmetros S e V .

Fonte: Autoria Própria

A conversão de uma imagem do sistema RGB para HSV é efetuado da seguinte forma: primeiro é verificado a faixa de valores do RGB. Com essa faixa é definido a variável “ m ” como o valor mínimo de cada canal RGB, ou seja:

$$m = \min(R, G, B) \quad (4)$$

O componente valor “ V ” do HSV é definido com o valor máximo de cada canal RGB demonstrado na equação (5)

$$V = \max(R, G, B) \quad (5)$$

Já a faixa de valores da componente saturação “ S ” são determinados pela equação (6)

$$S = \begin{cases} \frac{V-m}{V} & \text{se } V \neq 0 \\ 0 & \text{se } V = 0 \end{cases} \quad (6)$$

Por último para a componente matiz “ H ” a equação (7) define os valores desse canal:

$$H = \begin{cases} 60^\circ \left(\frac{G-B}{V-m} \right) & \text{se } V = R \\ 60^\circ \left(\frac{B-R}{V-m} + 2 \right) & \text{se } V = G \\ 60^\circ \left(\frac{R-G}{V-m} + 4 \right) & \text{se } V = B \end{cases} \quad (7)$$

É importante notar que quando $V = m$ o componente “ H ” é indefinido (BEYERER; PUENTE LEÓN; FRESE, 2016a). Os valores de máximo e mínimo do espaço de cores RGB são determinados de acordo com a aplicação. De maneira geral, em códigos de programação a faixa de valores está compreendida entre [0, 255].

O espaço de cores HSV pode ser utilizado para identificar cores de imagens com menor complexidade. Uma abordagem utilizada para identificar cores específicas é o emprego de lógica *fuzzy*, que será discutida na seção 2.5.2. Além de analisar a imagem como um todo, pode ser utilizado somente uma das bandas de cores do modelo de cores para extrair informações relevantes da imagem. Um exemplo, seria utilizar o canal “ S ” para analisar a saturação das cores que constituem a imagem.

2.5.2 SEGMENTAÇÃO

A fase de segmentação em PDI é responsável por extrair regiões ou objetos de interesse da imagem de entrada, diferenciando do “fundo” da imagem (RUSS; NEAL, 2016b). Esse é o ponto principal e mais complexo em análise de imagens, pois é a partir da segmentação que se definirá o fracasso ou sucesso dos procedimentos executados na análise computacional das imagens (GONZALEZ; WOODS, 2010). Além disso, analisar pontos de interesse segmentados permite extrair informações específicas com maior precisão, podendo esse procedimento fornecer

informações como posição e orientação dos objetos de interesse (BEYERER; PUENTE LEÓN; FRESE, 2016b). Uma abordagem para segmentar pontos de interesse é utilizar os valores de interesse desses pontos.

Duas principais categorias baseadas em valores de intensidade utilizadas para efetuar segmentação são: análise de similaridade e descontinuidade. A primeira é baseada na expectativa de que haja alguma similaridade entre os pixels das características de interesse e que haja alguma diferença entre os pixels de interesse e o “fundo” (parte que não se tem interesse) da imagem, de modo que a mesma possa ser dividida em regiões semelhantes. Essa semelhança pode ser na luminosidade ou cor. Já a segunda abordagem consiste em dividir a imagem a partir de mudanças bruscas de intensidade como, por exemplo, bordas de um objeto (GONZALEZ; WOODS, 2010; RUSS; NEAL, 2016b).

2.5.2.1 Segmentação por Cores

Uma metodologia para segmentar pontos de interesse por sua cor é utilizar lógica *fuzzy*. Esta define funções e o grau de pertinência para faixas de valores. Essa lógica permite a verificação de quão pertinente um valor está para uma classe. Assim, é possível encontrar cor específica com precisão (CAPONETTI; CASTELLANO, 2017b). Como neste trabalho será utilizado o sistema HSV para distinguir cores, é necessário conhecer o conjunto de funções *fuzzy* do espaço de cores HSV e desta forma, a Figura 11 representa esse conjunto de funções.

A segmentação de cor no espaço HSV através da lógica *fuzzy* é iniciada com a definição de tonalidade da cor que se deseja segmentar, ou seja, a faixa de valores do canal “*H*”. Após é preciso determinar a variação que essa tonalidade pode ter, sendo esses valores definidos pelos canais “*S*” e “*V*”. No código de programação, a verificação da cor através de lógica *fuzzy* é efetuada com condições “Se” e “Então” em conjunto da operação lógica “E”, representado por “ \wedge ”, entre as funções de pertinência dos canais HSV. Assim, a equação (8) apresenta a condição executada para verificar se uma cor específica foi identificada:

$$SE(H_B \leq H \leq H_A) \wedge (S_B \leq S \leq S_A) \wedge (V_B \leq V \leq V_A) ENTÃO \quad (8)$$

na qual, as letras “A” abaixo de cada variável indicam o limite superior e a letra “B” limite inferior (CAPONETTI; CASTELLANO, 2017b). Considere o seguinte exemplo de identificação de cor.

Se for desejado encontrar objetos azuis, a equação (8) a partir das funções de pertinência definidas na Figura 11 fica: $SE 180 \leq H \leq 270 \wedge 16 \leq S \leq 100 \wedge 16 \leq V \leq 100$. Caso os valores dos canais HSV com a sua variação de saturação e luminosidade satisfaçam a condição definida, a cor azul foi identificada. Porém, é necessário atentar que nesse caso foi considerado toda a função de pertinência da cor azul, ou seja, a cor poderá ter misturas de ciano ou roxo quando sua função cruzar com as funções de pertinência dessas cores, como pode ser visualizado na Figura 11.

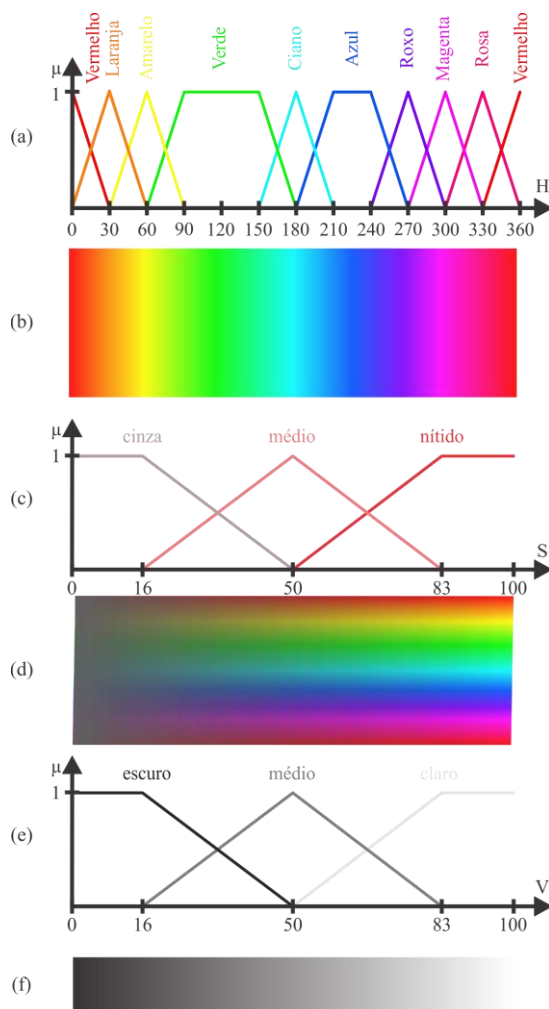


Figura 11 - Funções *Fuzzy* para cada canal do espaço de cores HSV com suas respectivas faixa de valores. (a) Funções de pertinência para o canal H . (b) Representação das cores definidas pelas funções de pertinência de H . (c) Funções de pertinência do canal S . (d) Representação das cores definidas pelas funções de pertinência de S . (e) Funções de pertinência do canal V . (f) Representação das cores definidas pelas funções de pertinência de V .

Fonte: Adaptado de Caponetti e Castellano (2017b, p. 77,78).

2.5.2.2 Identificação de Bordas

Detectar bordas é uma operação eficiente para segmentar pontos de interesse a partir de variações locais abruptas de intensidade. Vários métodos utilizam análise de derivadas, gradiente e limiarização para verificar se o local analisado possui pontos que possam ser bordas. O algoritmo desenvolvido por Canny utiliza essas ferramentas e o mesmo pode ser dividido em quatro etapas (GONZALEZ; WOODS, 2010).

O algoritmo inicia com a execução de suavização da imagem por um filtro gaussiano. Utiliza-se esse filtro, pois Canny percebeu que a análise da primeira derivada de uma gaussiana é um ótimo detector de bordas. Essa suavização é efetuada pela convolução da imagem de entrada por uma máscara gaussiana de tamanho $n \times n$. Essa convolução é executada pela equação (9) (GONZALEZ; WOODS, 2010)

$$f_s(x, y) = G(x, y) * f(x, y) \quad (9)$$

onde $f_s(x, y)$ é a imagem suavizada, $G(x, y)$ é a máscara gaussiana e $f(x, y)$ é a imagem a ser suavizada. O tamanho da máscara gaussiana é definido a partir da amostragem da equação (10) (GONZALEZ; WOODS, 2010)

$$G(x, y) = e^{-\frac{x^2+y^2}{2\sigma^2}}, \quad (10)$$

sendo que o tamanho “ n ” da máscara deve ser o menor inteiro ímpar maior ou igual que 6σ que suavize todo o filtro gaussiano aplicado na imagem. A Figura 12 demonstra um exemplo da máscara gaussiana 5 x 5.

0	0	-1	0	0
0	-1	-2	-1	0
-1	-2	-16	-2	-1
0	-1	-2	-1	0
0	0	-1	0	0

Figura 12 - Exemplo de máscara gaussiana 5 x 5 e seus coeficientes.

Fonte: Adaptado de Gonzalez e Woods, (2010, p. 471).

No segundo passo, é efetuado o cálculo da magnitude e direção do gradiente pelas equações (11) e (12) (GONZALEZ; WOODS, 2010)

$$M_G(x, y) = \sqrt{g_x^2 + g_y^2} \quad (11)$$

$$\alpha(x, y) = \text{tg}^{-1} \left[\frac{g_y}{g_x} \right] \quad (12)$$

onde $M_G(x, y)$ representa a magnitude e $\alpha(x, y)$ a direção do gradiente e “ g_x ” e “ g_y ” são as derivadas parciais em “ x ” e “ y ” da imagem suavizada. “ g_x ” e “ g_y ” podem ser obtidos através da aplicação das máscaras dos filtros propostos por Roberts, Prewitt e Sobel (GONZALEZ; WOODS, 2010), que são apresentadas na Figura 13.

-1	-1	-1	-1	0	1	-1	-2	-1	-1	0	1	-1	0	-1	0
0	0	0	-1	0	1	0	0	0	-2	0	2	0	1	0	1
1	1	1	-1	0	1	1	2	1	-1	0	1				
(a)			(b)			(c)			(d)			(e)		(f)	

Figura 13 – Máscaras utilizadas para detecção de bordas. Máscara de Prewitt: horizontal (a), vertical (b). Máscara de Sobel: horizontal (c), vertical (d). Máscara de Roberts (e) e (f).

Fonte: Adaptado de Gonzalez e Woods, (2010, p. 467).

Como no cálculo executado pela equação (11) são gerados máximos locais que podem indicar falsas bordas, no terceiro passo é empregado uma técnica de supressão dos não máximos. Uma abordagem para essa supressão é especificar um número de orientações discretas do vetor

gradiente. Assim, o terceiro passo pode ser executado da seguinte forma: primeiro encontre uma direção “ d_k ” mais próxima de $\alpha(x, y)$; subsequentemente verifique se $M(x, y)$ tem valor inferior de no mínimo dois de seus vizinhos ao longo de “ d_k ”. Caso isso seja verdade, $g_N(x, y) = 0$ que é a supressão. Se for falso, a condição fica $g_N(x, y) = M(x, y)$, onde $g_N(x, y)$ sendo essa a imagem com supressão de não máximo (GONZALEZ; WOODS, 2010).

No quarto e último passo é necessário fazer a limiarização. Esse processo é responsável por remover “falsas bordas”, sendo utilizado uma limiarização por histerese que consiste em utilizar dois limiares ao invés de um, sendo um limiar superior “ T_H ” e outro inferior “ T_L ”. A proporção sugerida por Canny entre os limiares é o limiar superior ser um valor entre duas e três vezes maior que o limiar inferior. No processo de limiarização serão geradas duas imagens, uma contendo o resultado do limiar inferior e outra do superior, sendo essas geradas pelas equações (13) e (14) (GONZALEZ; WOODS, 2010)

$$g_{NH}(x, y) = g_N(x, y) \geq T_H \quad (13)$$

$$g_{NL}(x, y) = g_N(x, y) \geq T_L \quad (14)$$

sendo que $g_{NL}(x, y)$ possuirá mais pixels que $g_{NH}(x, y)$ devido ao nível do limiar. Na sequência é eliminado todos os pixels diferente de zero pela equação (15) (GONZALEZ; WOODS, 2010)

$$g_{NL}(x, y) = g_{NL}(x, y) - g_{NH}(x, y) \quad (15)$$

no qual os pixels diferentes de zero em $g_{NL}(x, y)$ e $g_{NH}(x, y)$ podem ser considerados de borda fracos e fortes, pois a imagem g_{NL} possui pontos de borda referente ao limite inferior de limiarização e a imagem g_{NH} os pontos de borda do limite superior. Com o processo de limiarização finalizado, os pixels fortes de $g_{NH}(x, y)$ são marcados como borda, em que a imagem contendo o resultado do algoritmo de Canny forma-se com a atribuição dos pixels de $g_{NL}(x, y)$ diferentes de zero a $g_{NH}(x, y)$ (GONZALEZ; WOODS, 2010).

2.5.3 FILTRO ESPACIAL DE SUAVIZAÇÃO

No procedimento de adquirir imagens, alguns problemas na sua aquisição podem ocorrer. Por exemplo, imperfeições no sensor da câmera e iluminação não uniforme podem ser classificados como ruído de aquisição, sendo este caracterizado por flutuações nos valores dos pixels que não se caracterizam com a imagem obtida (RUSS; NEAL, 2016c). Desta forma é necessário executar procedimentos para corrigir problemas oriundos na aquisição da imagem. Essa correção, em grande parte dos casos, é efetuada antes de extrair as informações desejadas da imagem, para que assim, locais de ruído não influenciem no resultado da segmentação das características. Uma técnica que pode ser utilizada para corrigir ruídos de aquisição é o emprego de filtros espaciais de suavização, conhecido também como filtro passa baixa.

Filtro espacial pode ser considerado como a utilização de vizinhança (ou máscara), onde está pré-definida uma operação entre os pixels da imagem e da vizinhança (GONZALEZ; WOODS, 2010). Um exemplo de máscara em uma imagem é demonstrado na Figura 14.

A operação de filtragem ocorre com o deslocamento da máscara na imagem, onde a cada operação realizada o pixel central da máscara ou o pixel marcado a ser substituído é alterado pelo resultado da operação. A operação de média dos pixels da vizinhança da máscara é comumente utilizada, sendo intitulada de filtro de média (GONZALEZ; WOODS, 2010). A construção de uma máscara de filtragem pode ser efetuada a partir da equação (16)

$$M = \frac{1}{n \cdot n} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix}_{n \times n}, \quad (16)$$

onde “ M ” representa a máscara e “ n ” o tamanho da máscara. A partir da Figura 14 cada coeficiente “ W ” da máscara apresentado na imagem, será substituído por um dos valores gerados pela equação (16).

Com a substituição do valor do pixel da imagem pela média de sua vizinhança, pretende-se reduzir alterações abruptas indesejadas na imagem, ou seja, suavizar a imagem. Porém, o tamanho do filtro pode suavizar também bordas de objetos, que são alterações abruptas. Portanto, é necessário a escolha de uma dimensão da máscara que remova detalhes indesejáveis, mas preserve ao máximo as qualidades da imagem (GONZALEZ; WOODS, 2010).




Figura 14 - Exemplo de máscara em uma imagem. (a) apresenta a imagem original, (b) os pixels da seção da imagem sob a máscara e (c) os coeficientes do filtro. Nesse exemplo a máscara possui dimensão 3 x 3.

Fonte: Gonzalez e Woods, (2010, p. 95).

2.5.4 OPERAÇÕES EM IMAGENS BINÁRIAS

Após a segmentação dos pontos de interesse, em alguns casos são geradas imagens binárias, onde as regiões de interesse são marcadas com a cor branca (1) e o restante com preto (0). Devido as características das imagens binárias é possível efetuar uma análise mais profunda e precisa dos objetos contidos na imagem (BEYERER; PUENTE LEÓN; FRESE, 2016c). Assim, é possível aplicar procedimentos que podem melhorar a extração de características e processamentos específicos nessas imagens como, por exemplo, alterações na morfologia das regiões binárias na imagem e análise de contorno.

2.5.4.1 Operações Morfológicas

Operações morfológicas tem origem na matemática através da teoria dos conjuntos que permitem a análise e alterações na morfologia de conjuntos de pixels em imagens. A análise da morfologia pode ser efetuada em imagens binárias ou em escala de cinza. Imagens binárias possuem uma descrição da sua morfologia, representado pelos pixels marcados como 1, que estão no espaço 2-D de número inteiros Z^2 , que consistem em conjuntos de vetores com coordenadas (x, y) . Para executar essas operações é preciso definir um elemento estruturante (ES), que são

conjuntos de pixels usados a fim de analisar a morfologia dos pontos de interesse na imagem binária com origem que é definida de acordo com o problema (BEYERER; PUENTE LEÓN; FRESE, 2016c; GONZALEZ; WOODS, 2010). A Figura 15 apresenta um conjunto de ES com origem ao centro indicado pelo ponto preto.




Figura 15 - Conjunto onde são apresentados alguns ES comumente usados, onde (a) representa o ES em cruz, (b) o quadrado, (c) o retângulo e (d) uma elipse. Cada quadrado dos ES representados é um pixel. O ponto preto indica o centro do ES.

Fonte: Autoria Própria.

Esse tipo de operação consiste em deslocar o elemento estruturante por toda a imagem. A partir do tipo de operação que esteja sendo executada será excluído ou inserido pixels na porção da imagem binária. As duas principais operações morfológicas são a erosão e a dilatação. As outras operações consistem na associação dessas duas operações.

A operação de erosão, representada por “ \ominus ”, consiste em remover ou afinar objetos em imagens binárias a partir do deslocamento do elemento estruturante na imagem. Matematicamente a erosão pode ser descrita como

$$A \ominus B = \{w | (B)_w \subseteq A\}, \quad (17)$$

sendo a erosão de um conjunto de pixels A pelo ES B como o conjunto das translações de w por B em que cada conjunto de translações $(B)_w$ está totalmente contido em A . Assim, os pontos interiores ao objeto são mantidos, mas pontos da borda podem ser removidos (BEYERER; PUENTE LEÓN; FRESE, 2016c). A Figura 16 (b) e (c) ilustram a operação de erosão.

Já a dilatação, onde “ \oplus ” representa esta operação, faz o processo inverso, expandindo o objeto, sendo efetuada através da equação (18):

$$A \oplus B = \{w | (B^R)_w \cap A \neq \emptyset\}, \quad (18)$$

onde a dilatação de um conjunto “ A ” por um ES “ B ” é determinado pela translação de “ W ” por “ B ” onde as intersecções de “ A ” e “ $(S)_w$ ” transladado não seja um conjunto vazio (BEYERER; PUENTE LEÓN; FRESE, 2016c). A Figura 16 (f) e (g) apresentam a execução da operação de dilatação em um objeto.

Operações isoladas de dilatação e erosão podem proporcionar resultados que modificam em excesso a morfologia do objeto. No entanto, é possível aplicar uma operação subsequentemente da outra, proporcionando resultados mais precisos. Duas operações que resultam de operações subsequentes de dilatação e erosão ou vice e versa são chamadas de abertura e fechamento.

O procedimento de abertura é executado pela equação (19), representado por “ \circ ”

$$A \circ B = (A \ominus B) \oplus B \quad (19)$$

sendo uma erosão seguida de uma dilatação pelo mesmo ES. Essa operação permite remover pontos indesejados ou conexões estreitas que sejam menor que o ES e preserva pontos maiores (BEYERER; PUENTE LEÓN; FRESE, 2016c). A Figura 16 (e) apresenta a operação de abertura em um elemento.

A operação de fechamento preserva objetos ou conexões estreitas e fecha pontos em aberto dentro do elemento. A equação (20) descreve esse procedimento (BEYERER; PUENTE LEÓN; FRESE, 2016c), no qual “ \bullet ” indica a operação de fechamento. A Figura 16 (i) demonstra o resultado do procedimento de fechamento em um elemento.

$$A \bullet B = (A \oplus B) \ominus B \quad (20)$$

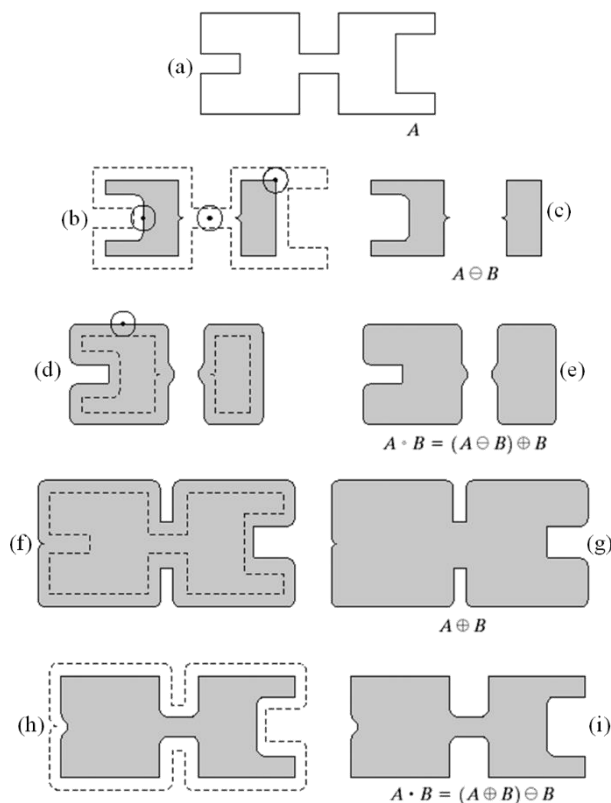


Figura 16 - Operações morfológicas em um objeto. O ES é o círculo com um ponto central marcado. (a) Objeto; (b) Procedimento de erosão; (c) Resultado da erosão; (d) Procedimento de abertura; (e) Resultado da abertura; (f) Procedimento de dilatação; (g) Resultado da dilatação; (h) Procedimento de fechamento; (i) Resultado do fechamento.

Fonte: Adaptado de Gonzalez e Woods, (2010, p. 421).

2.5.4.2 Contornos

A partir de imagens binárias, contendo os objetos segmentados, é possível efetuar análise geométrica desses objetos através de seus contornos. Uma abordagem para encontrar a borda de objetos em imagens binárias é utilizar seguidores de borda e análise de vizinhança.

Suzuki e Be (1985) desenvolveram um algoritmo que efetua uma análise topológica de imagens binárias a partir de seguidores de borda para encontrar o contorno de objetos em imagens binárias. Nesse algoritmo são efetuadas verificações entre regiões marcadas como 1 e 0 e a vizinhança desses pixels. Assim, a imagem é percorrida procurando locais onde a transição de 0 para 1 ou vice e versa ocorra. Conforme encontrados os pontos de transição, o algoritmo poderá marcar o ponto como sendo ou não parte do contorno da região.

2.6 CLASSIFICAÇÃO

Após segmentados objetos de interesse da imagem, métodos de reconhecimento de padrões podem ser empregados para classificar esses objetos. O uso de classificadores torna possível analisar pontos de interesse com maior agilidade. Além disso, o uso de técnicas de classificação possibilita o desenvolvimento de tecnologias autônomas e melhorias na execução de uma atividade. Como, por exemplo, utilizar estes métodos em conjunto com técnicas de PDI para encontrar veículos e pessoas em imagens aéreas de forma automática, pode facilitar missões de resgate e procura de pessoas em ambientes de difícil acesso (GASZCZAK; BRECKON; HAN, 2011).

Antes de utilizar métodos de reconhecimento de padrões em imagens, é preciso primeiro definir o que se deseja reconhecer. Também é necessário extrair características do objeto a ser reconhecido. Esta extração pode melhorar a classificação, pois ao serem aplicados algoritmos que extraem características muitas destas serão únicas para aquele tipo de objeto, sendo esse o ponto principal para distinguir objetos.

2.6.1 HISTOGRAMA ORIENTADO AO GRADIENTE

Características de objetos são essenciais em sua análise e reconhecimento. Diante disso, vários grupos de pesquisa desenvolveram técnicas com objetivo de extrair características locais das imagens, sendo essas denominadas descritores. Um descritor amplamente utilizado é o histograma orientado ao gradiente – *Histogram of Oriented Gradient* (HOG). Proposto por Dalal e Triggs (2005) para detectar pessoas. Este descritor está sendo utilizado para resolver outros problemas de reconhecimento de padrões em imagens (NIXON; AGUADO, 2012), sendo um exemplo, o uso de HOG para detectar sinalização de trânsito (SUGIHARTO; HARJOKO, 2016). Esse descritor é invariante à transformações geométricas e fotométricas (DALAL; TRIGGS, 2005).

O descritor HOG de uma imagem é obtido da seguinte forma: primeiro é obtido as bordas da imagem por um detector de bordas como, por exemplo, o detector de Sobel (DALAL; TRIGGS, 2005). Formada a imagem contendo as bordas, é calculado a magnitude e direção dos pixels que compõem as bordas detectadas e o resultado é armazenado em um histograma. Depois, a imagem é dividida em células contendo 8 x 8 elementos e para cada célula é calculado um histograma de

gradientes, onde esse valor pode ser alterado conforme a necessidade. Esse procedimento de histograma local permite que a imagem seja descrita de forma compacta e menos sensível ao ruído. O histograma gerado é um vetor composto por um conjunto de 9 valores denominado *bins*, correspondendo a ângulos com intervalos de 20° . Ou seja, a direção do gradiente é armazenada de forma equidistante com um intervalo definido. Então, o gradiente da célula é analisado de forma que em cada valor *bin* seja armazenado a magnitude, gerando assim o histograma do gradiente. Assim, é efetuado normalização de contraste local em blocos como, por exemplo, blocos de 3×3 células, diminuindo assim, eventuais variações na magnitude do gradiente devido alterações na iluminação. Por fim os histogramas são agrupados em blocos como, por exemplo, de 3×3 (NIXON; AGUADO, 2012). A Figura 17 apresenta um exemplo de obtenção do HOG.

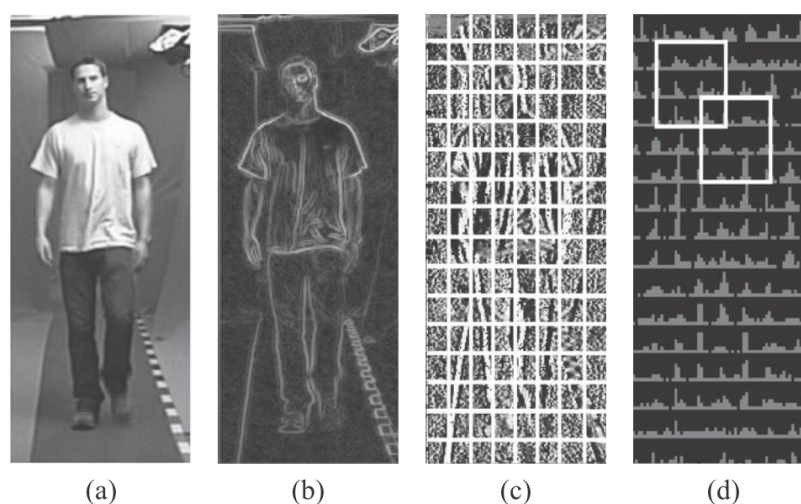


Figura 17 - Exemplo de descritor HOG. (a) Imagem original, (b) Bordas da imagem, (c) Células 8×8 , (d) Agrupamento de histogramas em blocos 3×3 .

Fonte: Modificado de Nixon e Aguado, (2012, p. 242).

2.6.2 SVM

Support Vector Machine (SVM) é um método de reconhecimento de padrões que originalmente foi desenvolvido com o objetivo de classificar somente duas classes. Posteriormente ele foi modificado para suportar problemas com várias classes (SHIH, 2010). O classificador SVM é baseado na obtenção de um hiperplano que contenha os dados das amostras de treinamento. Os vetores de suporte são as amostras de treinamento que definem a separação ótima do hiperplano, sendo estas as amostras mais difíceis de serem classificadas. Estas possuem os padrões com maior quantidade de informações, sendo utilizadas na tarefa de treinamento para assim classificar

amostras submetidas a esta técnica de reconhecimento de padrões (DUDA; HART; STORK, 2001).

A Figura 18 fornece um exemplo de separação dos dados pelo hiperplano, sendo este linear. Considere as duas classes contidas na imagem (círculos vermelhos e pretos). Na fase de treinamento, o algoritmo do SVM procurará as amostras que separam de forma ótima uma classe da outra. Entretanto, existe um limite entre o hiperplano ótimo e as amostras que separam as classes. Na Figura 18 é possível verificar que ao lado da linha do hiperplano ótimo, existem linhas laterais, que definem esse limite, sendo a distância entre a linha do hiperplano e as linhas laterais definidas por uma margem máxima. No exemplo da Figura 18, as amostras mais difíceis de classificar são os círculos preenchidos, onde para a classe 1 é o círculo vermelho e para a classe 2 os círculos pretos. Assim, o algoritmo utilizará das informações dessas amostras para distinguir se uma amostra pertence a classe 1 ou a classe 2, sendo que nesse exemplo os vetores de suporte são constituídos das informações dos círculos preenchidos.




Figura 18 - Exemplo de conjunto de dados e hiperplano ótimo. Círculos em vermelho pertencem a classe 1 e círculos pretos a classe 2. As amostras preenchidas representam as amostras com maior complexidade de serem classificadas.

Os eixos y_1 e y_2 indicam as características das amostras.

Fonte: Duda, Hart e Stork, (2001, p. 50).

Com a revisão das técnicas que estão sendo utilizadas para monitorar rodovias através da análise de imagens é possível desenvolver uma metodologia, utilizando desta abordagem com o objetivo de aprimorar a inspeção de rodovias. Juntamente com as imagens adquiridas da rodovia é possível utilizar as ferramentas de processamento de imagens, que permitem extrair características da rodovia e identificar objetos na via de tráfego. Também é possível extrair características dos objetos identificados. Então, estas podem ser submetidas a métodos de reconhecimento de padrões, possibilitando classificar objetos extraídos da rodovia monitorada. Com esta classificação agregada ao processamento das imagens é possível desenvolver um sistema automático de inspeção de rodovias.

Diante destes fatos, este trabalho utilizará sensoriamento remoto, utilizando um VANT com câmera acoplada para sobrevoar e adquirir as imagens da rodovia. Associado a aquisição das imagens, as técnicas de análise de imagens apresentadas neste capítulo serão empregadas com o objetivo de extrair as características e os objetos da rodovia. Por fim, será utilizado método de reconhecimento de padrões que classificará os objetos segmentados da rodovia.

3 MATERIAIS E MÉTODOS

Neste capítulo serão apresentados os procedimentos utilizados para o desenvolvimento do trabalho e a metodologia empregada para efetuar a aquisição e processamento das imagens aéreas de rodovias. Serão apresentadas as técnicas de PDI aplicadas na segmentação da rodovia e dos objetos presentes na rodovia, além do método de reconhecimento de padrões empregado para classificar os objetos segmentados. A operação das técnicas utilizadas e a teoria destas estão presentes no capítulo 2.

As seções de um a quatro, do presente capítulo, apresentam as ferramentas utilizadas para adquirir as imagens e processá-las após sua aquisição. Já as seções cinco a oito, demonstram o algoritmo desenvolvido com as técnicas de PDI aplicadas para processar as imagens e os procedimentos executados para classificar os objetos identificados a partir da segmentação de objetos que o algoritmo desenvolvido executa.

3.1 ESPECIFICAÇÕES DO VANT E DA CÂMERA

O trabalho teve início com as especificações técnicas do VANT, empregado como meio para aquisição de imagens. Três pontos principais foram levados em consideração na escolha da RPAS: autonomia, câmera acoplada e sistemas de segurança e navegação. A câmera acoplada implica diretamente na autonomia, pois, dependendo do peso, o tempo de voo da aeronave será comprometido. O tempo de voo mínimo definido foi de 15 minutos com uma câmera de 12 Mpixels de resolução, com peso máximo de 600 g. Os sistemas de segurança mínimos desejados foram retorno automático, caso ocorra perda de sinal, pouso automático, quando o nível de bateria estiver baixo, e controle de estabilidade.

Na escolha do VANT, a preferência ficou por modelos com asa rotativa. Dentro das especificações definidas, o modelo que melhor atendeu aos requisitos foi o VANT Inspire 1 RAW, do fabricante DJI, que oferece até 18 minutos de voo. A câmera acoplada modelo X5R do fabricante DJI com 16 Mpixels de resolução e lente removível. O fabricante também disponibiliza software para navegação e configuração da aeronave (DJI, 2017). A Figura 19 apresenta o VANT escolhido para aquisição das imagens.



Figura 19 - VANT com câmera acoplada utilizado para aquisição das imagens.

Fonte: Autoria própria.

3.2 SISTEMA DE NAVEGAÇÃO DO VANT

Para configurações de modo de voo, alarmes do nível de bateria, configurações de retorno automático, visualização de imagens em tempo real, parâmetros dos instrumentos e pilotagem do VANT, foi utilizado o aplicativo para dispositivos móveis DJI GO APP para iOS, disponibilizado pelo fabricante do VANT (DJI, 2017). A Figura 20 apresenta algumas telas da interface do aplicativo. Neste aplicativo, é possível efetuar as configurações de retorno em caso de perda de sinal, alarmes referentes ao nível da bateria, limites de altura e distância do equipamento em relação ao piloto e modos de voo. O aplicativo também oferece mapa indicando a posição do VANT, caminho percorrido e caminho que será percorrido em caso de retorno automático. Referente a telemetria e dados de uso da aeronave, no aplicativo é possível verificar e exportar todos os voos executados com todas as informações, como velocidade, altura, bateria entre outras.

Além do software disponibilizado pelo fabricante, existe a possibilidade de utilizar outros aplicativos para controlar a aeronave. Várias empresas desenvolveram aplicativos que permitem efetuar voos diferenciados, que não estão disponíveis no aplicativo padrão. Estes permitem configurar e executar voos automáticos para capturar imagens e formar um mosaico. Um exemplo é o Pix4Dcapture (PIX4D, 2017a).

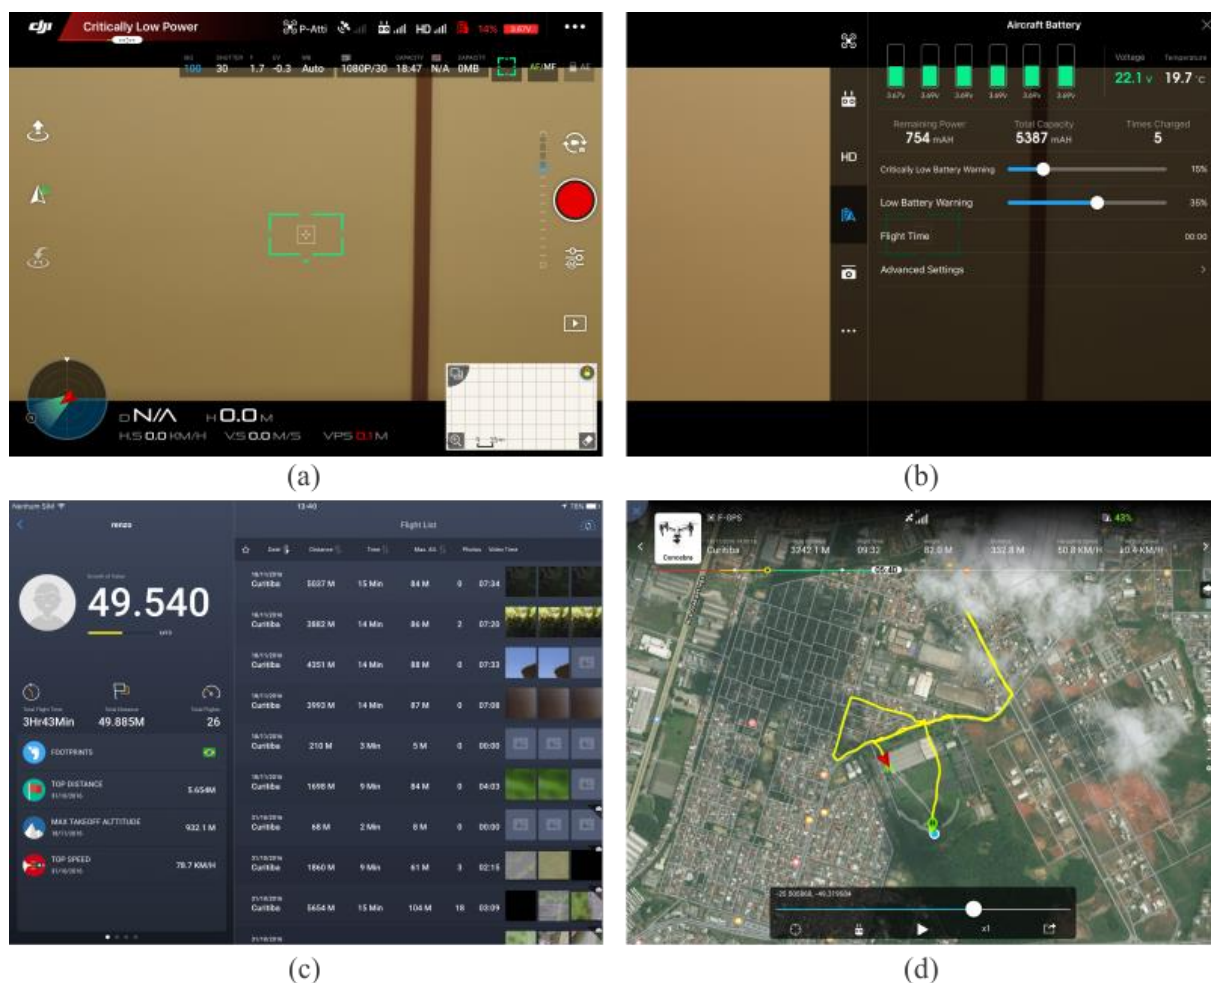


Figura 20 - Telas do aplicativo para pilotagem do VANT. (a) Tela principal que contém informações de todos os instrumentos, (b) Configurações de bateria, (c) Registro de voo, (d) Revisão de voo.

Fonte: Autoria Própria.

3.3 GERAÇÃO DE ORTOMOSAICO

Ao invés de adquirir vídeos de ambientes a serem monitorados, uma ferramenta utilizada pela indústria é a geração de mosaico de fotos, chamado de ortomosaico. Ortomosaicos são gerados através da aquisição de imagens com margem de sobreposição, onde várias imagens são adquiridas em uma rota de voo com uma diferença de distância definida automaticamente, conforme o nível de sobreposição que se deseja. Após a aquisição, um algoritmo unirá essas imagens, gerando uma única imagem de alta resolução. A grande vantagem dessa técnica é que toda a imagem é georreferenciada, permitindo o cálculo de áreas e distâncias na imagem, além de permitir a geração de modelos tridimensionais e modelos digitais de superfície que permitem a análise do relevo do terreno (AWANGE; KYALO KIEMA, 2013).

Para adquirir as imagens que geraram o mosaico de fotos, utilizou-se o aplicativo Pix4Dcapture para iOS (PIX4D, 2017a). Este aplicativo permite configurar a área onde serão capturadas as imagens e o nível de sobreposição desejado. A partir destas informações, o aplicativo define os pontos onde serão adquiridas as imagens e configura o VANT para um voo automático. Como não é permitido voos totalmente automáticos no Brasil (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2017a), o piloto pode, a qualquer momento, alterar o modo de voo, adquirindo o controle da aeronave.

A geração do ortomosaico é efetuada através do software Pix4Ddesktop (PIX4D, 2017b) a partir das imagens capturadas. A Figura 21 (a) apresenta a interface do aplicativo e a Figura 21 (b) interface do software para computadores.

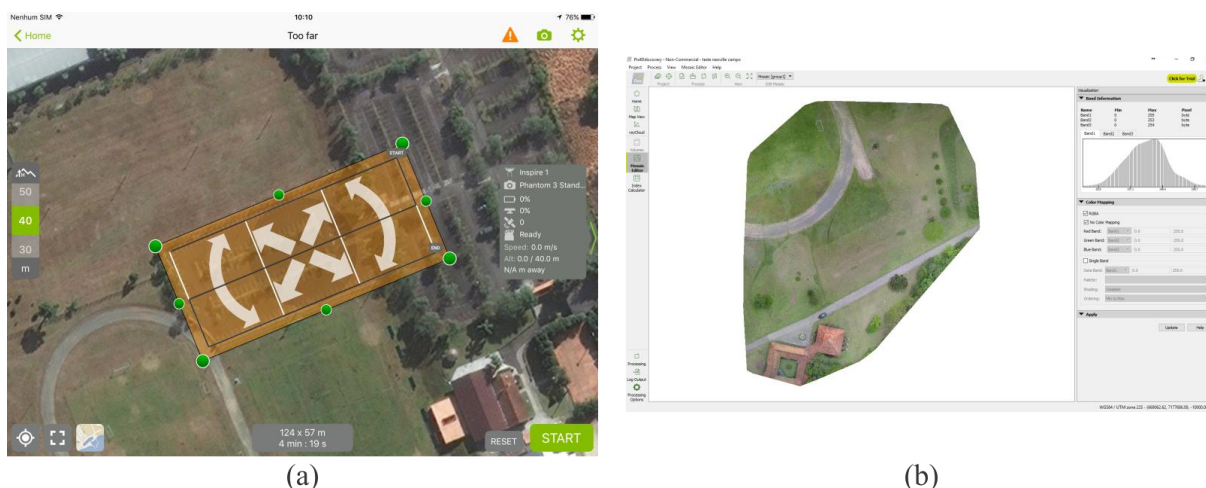


Figura 21 - Softwares utilizados para adquirir imagens e gerar ortomosaicos. (a) Aplicativo para dispositivo móvel Pix4Dcapture. Na tela apresentada é possível marcar a área onde o VANT sobrevoará para aquisição das imagens, configurar a altura de voo e visualizar informações dos instrumentos do VANT. Em (b) é apresentado o software para processamento das imagens adquiridas. A tela em (b) demonstra um ortomosaico gerado no software Pix4Ddesktop. Fonte: Autoria Própria.

Para gerar o mosaico, processar as imagens para extrair características e treinar o classificador de padrões, é necessário um sistema computacional que proporcione respostas rápidas quando imagens forem submetidas para processamento.

3.4 SISTEMA COMPUTACIONAL

Para desenvolvimento do algoritmo e processamento das imagens, foi utilizado um computador equipado com CPU Core i7-4790, 16 GB RAM e processador gráfico (ou GPU) Nvidia GTX 650 Ti 2 GB GDDR5.

Como linguagem de programação, foi utilizado C++ em conjunto com a API OpenCV que possui vários algoritmos implementados e otimizados para processamento de imagens (KAEHLER; BRADSKI, 2016).

Referente ao sistema operacional, foi utilizado o Ubuntu 64-bits e Windows 10 Pro 64-bits. Com esse sistema computacional foi possível executar o algoritmo desenvolvido e gerar os ortomosaicos, permitindo obter respostas rápidas no processamento das imagens submetidas ao algoritmo em execução nesse sistema computacional.

3.5 PROCEDIMENTOS PARA AQUISIÇÃO E PROCESSAMENTO DE IMAGENS

Definido o VANT e a câmera para captação das imagens, foi necessário o desenvolvimento de procedimento para executar as missões em campo, gerando então um *checklist* de voo que é apresentado no APÊNDICE A.

Todos os voos executados antes de maio de 2017, seguiram a RBAC-E nº 94 publicada para consulta pública em 2015 (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2015). Após maio de 2017, a RBAC-E nº 94 foi oficializada, sendo seguida após sua publicação (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2017a). Também foi utilizado o sistema SARPAS disponibilizado pelo DECEA onde, após cadastro da aeronave e do piloto, é possível efetuar a solicitação de espaço aéreo. Para a solicitação, o piloto deve informar ponto de decolagem, área solicitada e modo de operação. A partir da solicitação aprovada são enviadas, em conjunto da aprovação, recomendações para execução do voo. Caso seja rejeitada a solicitação, os motivos são esclarecidos (DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO, 2017).

Os testes em campo iniciaram com a avaliação de imagens adquiridas em diferentes alturas, sendo o melhor nível de detalhe obtido para imagens adquiridas entre 30 e 80 metros de altura, com câmera posicionada a 90° em relação à superfície da pista. As imagens foram adquiridas em vídeo com resolução de 4096 x 2160 ou 1920 x 1080, com 24 quadros por segundo, possibilitando velocidade média de voo de 60 km/h. Os vídeos foram adquiridos utilizando o

sistema de navegação DJI GO. Quando utilizado o aplicativo Pix4Dcapture com a intenção de gerar ortomosaico, as imagens foram adquiridas em resolução 4608 x 3456 pixels.

Os primeiros testes tiveram imagens capturadas em ambiente restrito, no campus Neville da Universidade Tecnológica Federal do Paraná (UTFPR), em Curitiba (latitude 25°30'22.83"S e longitude 49°18'59.85"O). Em ambiente real, as imagens foram adquiridas na BR-060 km 107 na cidade de Goianópolis, Goiás (latitude 16°26'17.79"S e longitude 49° 1'6.64"O) e BR-153 km 500, na cidade de Goiânia, Goiás (latitude 16°44'51.82"S e longitude 49°14'27.46"O).

A partir das características e do modelo de uma rodovia em imagens aéreas apresentadas no capítulo 2, seção 2.2, foi definida uma metodologia de processamento das imagens adquiridas pela câmera acoplada ao VANT, para obter como produto final a classificação de objetos na rodovia.

Com base no conjunto de imagens adquiridas, foi desenvolvido um algoritmo que emprega técnicas de PDI para extrair as informações necessárias e classificá-las através de métodos de reconhecimento de padrões. A Figura 22 apresenta um fluxograma que resume o algoritmo desenvolvido, o qual é dividido em três partes: segmentação de rodovia (pré-processamento), segmentação de objetos e classificação de objetos identificados. Além dos passos do algoritmo, o fluxograma apresenta o tipo de imagem que está sendo utilizada na operação de processamento.

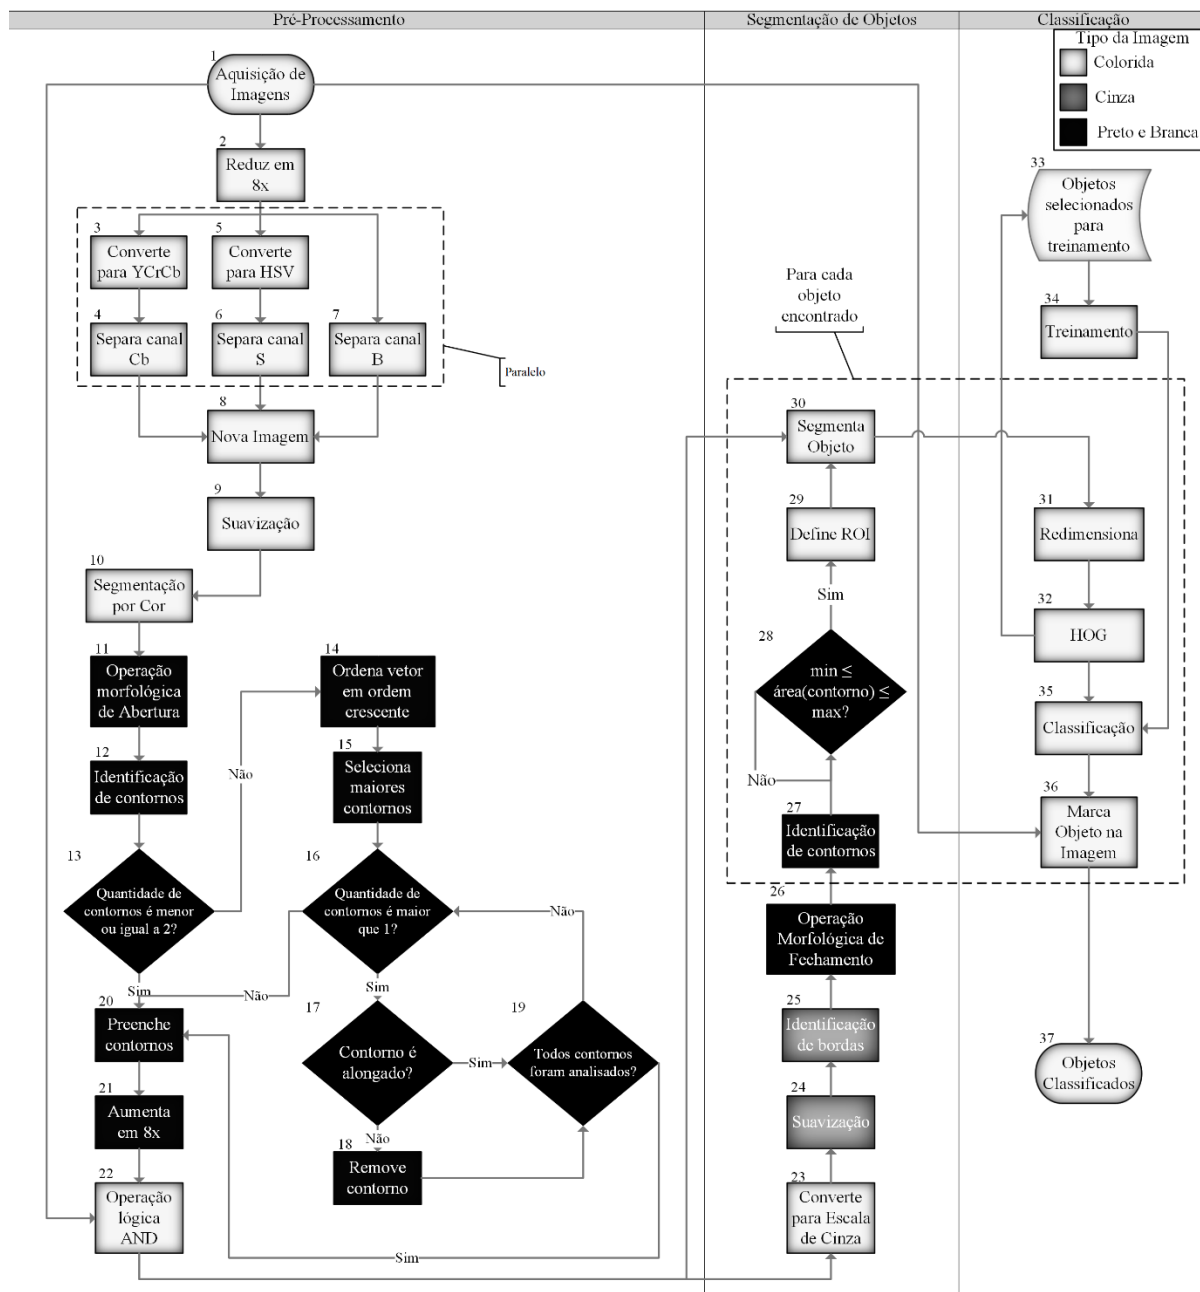


Figura 22 - Fluxograma de execução do algoritmo desenvolvido. A legenda no canto superior direito indica o tipo de imagem de acordo com a cor do bloco. Cada bloco é identificado por um número que indica a ordem das operações executadas.

Fonte: Autoria própria.

3.6 PRÉ-PROCESSAMENTO

Após aquisição das imagens (bloco 1 no fluxograma) é necessário efetuar um pré-processamento para segmentar a rodovia da imagem, retirando outros objetos que não são de

interesse. A execução desse procedimento é através de segmentação por cor, aplicação de operações morfológicas e análise da geometria dos segmentos indicados como rodovia. O trabalho desenvolvido por Jin e Feng (2010), o modelo de rodovia proposto por Baumgartner *et al.* (1999) e as características apresentadas por Wang *et al.* (2016) serão a base no desenvolvimento desta etapa.

Para melhor compreensão, a Figura 23 apresenta a resposta das etapas de pré-processamento do algoritmo. Como a Figura 23 possui várias imagens, cada número, entre parênteses abaixo de cada imagem, representa a etapa que está sendo executada no algoritmo apresentado na Figura 22. A imagem de exemplo submetida ao algoritmo está apresentada na Figura 23 (1).

A primeira tarefa que o algoritmo executa é redimensionar a imagem de entrada (bloco 2), reduzindo em 8 vezes sua dimensão com interpolação dos novos pixels. Para se obter a resolução de imagem a ser utilizada nessa etapa, foram efetuados testes com vários tamanhos. Após estes testes, a redução em 8 vezes apresentou o melhor resultado de desempenho na execução da segmentação da rodovia, tanto no tempo de execução, como no processo de segmentar a rodovia. Esse procedimento de redução pode ser visualizado na Figura 23 (2). Se comparada com a Figura 23 (1) é possível verificar que detalhes finos foram danificados, sendo considerada uma característica de imagem com baixa resolução.

De acordo com as características da rodovia apresentadas no capítulo 2, seção 2.2, a região pavimentada possui grande dimensão. Como nesta etapa não há interesse em detalhes finos, a segmentação da rodovia é efetuada com a imagem redimensionada. Essa operação tem como objetivo principal reduzir o tempo de processamento do algoritmo nas etapas subsequentes, pois a maior parte do ambiente da rodovia está envolvida por vegetação que possui pouca variação nos valores de cinza e brilho intenso. A segmentação da pista será iniciada com análise das cores da imagem.

A partir do trabalho desenvolvido por Jin e Feng (2010), utiliza-se a ideia de separar os canais de cores, proporcionando melhor análise. Assim, nas próximas etapas, é efetuada a alteração do sistema de cores da imagem RGB para YC_bC_r (bloco 3) e HSV (bloco 5).

Seguindo ainda a técnica proposta por Jin e Feng (2010), separados os canais de cores, é formada uma nova imagem com as informações mais relevantes sobre o asfalto, composta de canais distintos entre os espaços de cores (bloco 8).




Figura 23 - Resultado da etapa de segmentação da rodovia. Cada número abaixo da figura representa a etapa no fluxograma do algoritmo apresentado na Figura 22.

Fonte: Autoria Própria.

Pelo fato de as áreas de vegetação possuírem baixo valor de cores azul no sistema RGB (JIN; FENG, 2010), esse canal é separado da imagem (bloco 7) e está apresentado na Figura 23 (7). Esse princípio também é utilizado na imagem no espaço de cores YC_bC_r , onde é separado o componente “ C_b ” (bloco 4) que representa a diferença entre o brilho e a cor azul, que pode ser visualizado na Figura 23 (4). Já que a imagem no espaço HSV apresenta as intensidades de cores separadamente e uma via pavimentada possui baixo valor de saturação (JIN; FENG, 2010), esse canal é separado da imagem (bloco 6), apresentado na Figura 23 (6).

Com a união dos três canais, que identificam e distinguem a vegetação da pavimentação, é formada uma nova imagem (bloco 8) que proporcionará melhor distinção entre asfalto e vegetação. O resultado dessa operação é demonstrado pela Figura 23 (8).

Gerada a nova imagem é efetuada a segmentação da rodovia através de análise de cores. Porém, é possível verificar na Figura 23 (8) que objetos dentro da rodovia apresentam coloração diferenciada, se comparada com a via. Como esses pontos seriam desconsiderados na segmentação da rodovia é necessário unir os mesmos ao segmento de rodovia.

Logo, no próximo passo, a imagem é suavizada com um filtro da média com máscara 9×9 (bloco 9). Esse procedimento pode ser visualizado na Figura 23 (9). Suavizada a imagem, a segmentação por cores é efetuada através de lógica *fuzzy* da imagem no espaço HSV (bloco 10). Antes da segmentação por cores é necessária uma análise de quais cores se deseja identificar na nova imagem. Assim, a partir das funções de pertinência apresentadas na Figura 11, é verificado quais funções identificarão as cores desejadas. Como avaliação preliminar do processo de segmentação de cores, foram realizados testes utilizando o espaço de cores HSV e lógica *fuzzy* para identificação de objetos em movimento. Estes testes são apresentados no APÊNDICE B.

Com resultados positivos nos testes efetuados, analisou-se as partes da imagem que contém rodovia. Então, verificou-se que estas apresentam coloração magenta com saturação e valor maior que 50 no espaço HSV.

Com essas informações e a partir das funções de pertinência para o espaço de cores HSV, apresentadas na Figura 11, define-se a seguinte condição para segmentar a rodovia $SE\ 270 \leq H \leq 330 \wedge 50 \leq S \leq 100 \wedge 50 \leq V \leq 100$ então a cor magenta foi encontrada. Essa condição será verificada em cada pixel da imagem fornecida. Satisfeita a condição proposta, marca-se o pixel como 1, caso contrário como 0, formando uma imagem binária. O resultado desse processamento pode ser visualizado na Figura 23 (10).

Com a imagem binária fornecida pela segmentação é efetuado a operação morfológica de abertura com ES retangular (bloco 11) com dimensões 9 x 3 pixels, sendo o resultado apresentado na Figura 23 (11), que eliminará pontos indesejados preservando segmentos de rodovia identificados. O formato de ES escolhido leva em consideração as características apresentadas no capítulo 2, seção 2.2, onde os segmentos de rodovia são descritos com características geométricas alongadas, semelhante a um retângulo. Entretanto, nem todos os pontos indesejados são removidos.

No processo de segmentação por cores como, por exemplo, estacionamentos em áreas urbanas, podem ser considerados segmentos de rodovia. Como estas áreas possuem geometria diferente da rodovia, uma abordagem que pode ser utilizada para verificar se um segmento encontrado pertence ou não a uma rodovia, é efetuar análise da geometria desses segmentos (JIN; FENG, 2010).

Na análise da geometria é utilizado o algoritmo desenvolvido por Suzuki e Be (1985) para extrair o contorno de objetos em imagens binárias. Assim, a imagem resultante da operação morfológica de abertura é submetida a este algoritmo, fornecendo o contorno da rodovia extraída pela identificação de cores (bloco 12). O resultado obtido é apresentado na Figura 23 (12).

Se a quantidade de contornos encontrados for menor ou igual a 2, é considerado que a imagem possui somente segmentos de rodovia (bloco 13). A condição sobre a quantidade de contornos é atribuída pelo fato de rodovias duplicadas apresentarem 2 segmentos e vias simples e interseções apresentarem um segmento quando formado a imagem binária. Caso seja encontrado mais que 2 contornos, o vetor que armazena os contornos encontrados é reordenado em ordem decrescente (bloco 14), considerando, para a reordenação, a quantidade de pontos que o contorno possui. É considerado para análise de geometria a quantidade de pontos do contorno. Esta informação é utilizada porque os contornos com poucos pontos possuem pequenas áreas que podem indicar possíveis erros de segmentação.

Na sequência, esse vetor é analisado até encontrar a maior diferença entre a quantidade de pontos entre um elemento e outro do vetor (bloco 15). Quando essa diferença for encontrada, define-se que os valores antes do índice, onde a maior diferença foi encontrada, são os maiores contornos encontrados, indicando possíveis segmentos de rodovia. Então, os elementos anteriores a este índice são removidos.

Com o vetor armazenando somente possíveis segmentos de rodovia, primeiro é verificado se a quantidade de elementos restantes é maior que 1 (bloco 16). Se a condição for falsa, a imagem contém somente segmentos de rodovia e o algoritmo é redirecionado ao bloco 20. Caso contrário,

é verificada a proporção entre largura e altura de cada contorno restante na imagem (bloco 17). Caso algum objeto não tenha proporção menor que 0,9 entre largura e altura, esse não é considerado um segmento de rodovia e é removido (bloco 18). O valor de proporção foi definido a partir de testes experimentais, pois valores de limite inferiores a 0,9 estavam ocasionando na remoção de segmentos de rodovia com conexões. É através dessa análise de contorno que são eliminados possíveis objetos indesejados nas laterais da rodovia como, por exemplo, os estacionamentos.

Aceita a condição de proporção é verificado se todos os contornos já foram analisados (bloco 19). Caso seja positiva essa resposta, a etapa de verificação de geometria está encerrada e o algoritmo continua para a próxima etapa. Do contrário, o programa retorna ao bloco 16 para analisar novamente os segmentos. Ao término da análise de geometria, os contornos restantes são preenchidos (bloco 20) para que se possa, ao final do procedimento, restar somente segmentos de rodovia na imagem. O resultado do preenchimento está demonstrado na Figura 23 (20).

Além disso, para que a segmentação da rodovia seja efetuada, é necessário ainda redimensionar a imagem com os contornos preenchidos para a mesma dimensão da imagem de entrada (bloco 21), pois, no início do processamento, esta foi reduzida para melhorar o tempo de processamento do algoritmo.

Por fim, para se obter imagem contendo somente a rodovia, é efetuado a operação lógica “E” entre a imagem original e a imagem binária dos segmentos encontrados (bloco 22) segmentando assim, a rodovia da imagem. Este resultado está apresentado na Figura 23 (22). Com uma imagem contendo somente a rodovia, é possível identificar com maior precisão objetos sob a rodovia, que é o próximo passo que o algoritmo executa.

3.7 SEGMENTAÇÃO DE OBJETOS

Concluída a etapa de segmentação da rodovia é iniciado o processo para identificar e extrair objetos contidos na rodovia. Contudo, antes disso, foi necessário analisar quais objetos seriam de interesse. Para o funcionamento da rodovia, os principais componentes são as condições do pavimento e das marcações horizontais. Porém, é necessário também segmentar os veículos que circulam na rodovia para que uma análise de fluxo possa ser executada.

Diante disso, foi solicitado perante a equipe da concessionária de rodovias Triunfo Concebra, sendo esta a empresa parceira no desenvolvimento deste trabalho, quais seriam os principais pontos de interesse a serem identificados. Desta forma, cinco objetos de interesse foram

definidos para que sua segmentação fosse executada no processamento das imagens. Estes objetos são veículos, defeitos no pavimento, que são rachaduras ou buracos, e três marcações horizontais, sendo estas setas, traços e palavras.

Com as informações de quais objetos são de interesse para serem segmentados, a abordagem empregada na execução desta tarefa será utilizar as bordas dos objetos, através da análise de contraste entre o objeto e a rodovia. Portanto, o primeiro passo executado é converter a imagem para escala de cinza (bloco 23).

Para maior compreensão será utilizado como exemplo o resultado da segmentação da rodovia apresentado na Figura 23. O número entre parênteses apresentado junto a imagem representa a etapa que está sendo executada pelo algoritmo da Figura 22. Assim, a Figura 24 (23) apresenta a rodovia segmentada convertida em escala de cinza. A partir dessa imagem, é aplicado filtro de suavização da média com dimensão 5 x 5 para remover ruídos de aquisição da imagem original (bloco 24). O resultado está apresentado na Figura 24 (24). A não remoção desse ruído pode originar identificação de pontos falsos na execução do algoritmo de identificação de bordas.

Na próxima etapa é empregado o algoritmo de Canny, que identificará bordas dos objetos (bloco 25). Os limiares necessários para a execução do algoritmo foram definidos como sendo $T_L = 15$ e $T_H = 3T_L$, seguindo a orientação de Canny, onde é mencionado que a diferença de valor entre os limites deve ser de três vezes (GONZALEZ; WOODS, 2010). O resultado da aplicação do algoritmo pode ser visualizado na Figura 24 (25).

No entanto, é possível verificar que os contornos encontrados pelo algoritmo podem apresentar desconexões. Este problema é solucionado aplicando-se a operação morfológica de fechamento (bloco 26) com elemento estruturante retangular e dimensões 6 x 2 pixels, que conectará as bordas dos objetos (Figura 24 (26)). Após a segmentação, o objeto será classificado por um método de reconhecimento de padrões. Então, para incrementar as características de cada objeto, a região do ambiente no entorno do objeto também é segmentada.

Para que isso seja efetuado é definida a região de interesse – *Region of Interest* (ROI) (bloco 29) que marcará cada objeto encontrado na imagem da rodovia segmentada. Uma maneira de definir a ROI é a partir da borda do objeto, selecionar os pontos extremos (superior e lateral direito) e definir um retângulo no entorno do objeto. Com essa técnica será possível segmentar o objeto em conjunto com o ambiente em que o mesmo está inserido.

No entanto, antes é necessário extrair e analisar os contornos dos objetos encontrados (blocos 27 e 28). Os contornos encontrados na imagem de exemplo estão apresentados na Figura

24 (27). Com a análise dos contornos é possível descartar possíveis objetos fora da área de interesse.

Essa análise é efetuada a partir da área do objeto. Se a área não estiver em uma faixa definida o objeto é descartado, sendo analisado o próximo objeto (bloco 28). Do contrário, é definida a ROI do objeto encontrado. Esse procedimento pode ser visualizado na Figura 24 (30) onde os objetos estão envolvidos por um retângulo azul, que representa a ROI.

Definida a ROI a partir do contorno do objeto, o mesmo será segmentado da imagem da rodovia segmentada (bloco 30), sendo esse procedimento efetuado para cada objeto encontrado. Na Figura 24 (30) as setas indicam exemplos de objetos segmentados. Após segmentado o objeto será submetido ao método de reconhecimento de padrões.

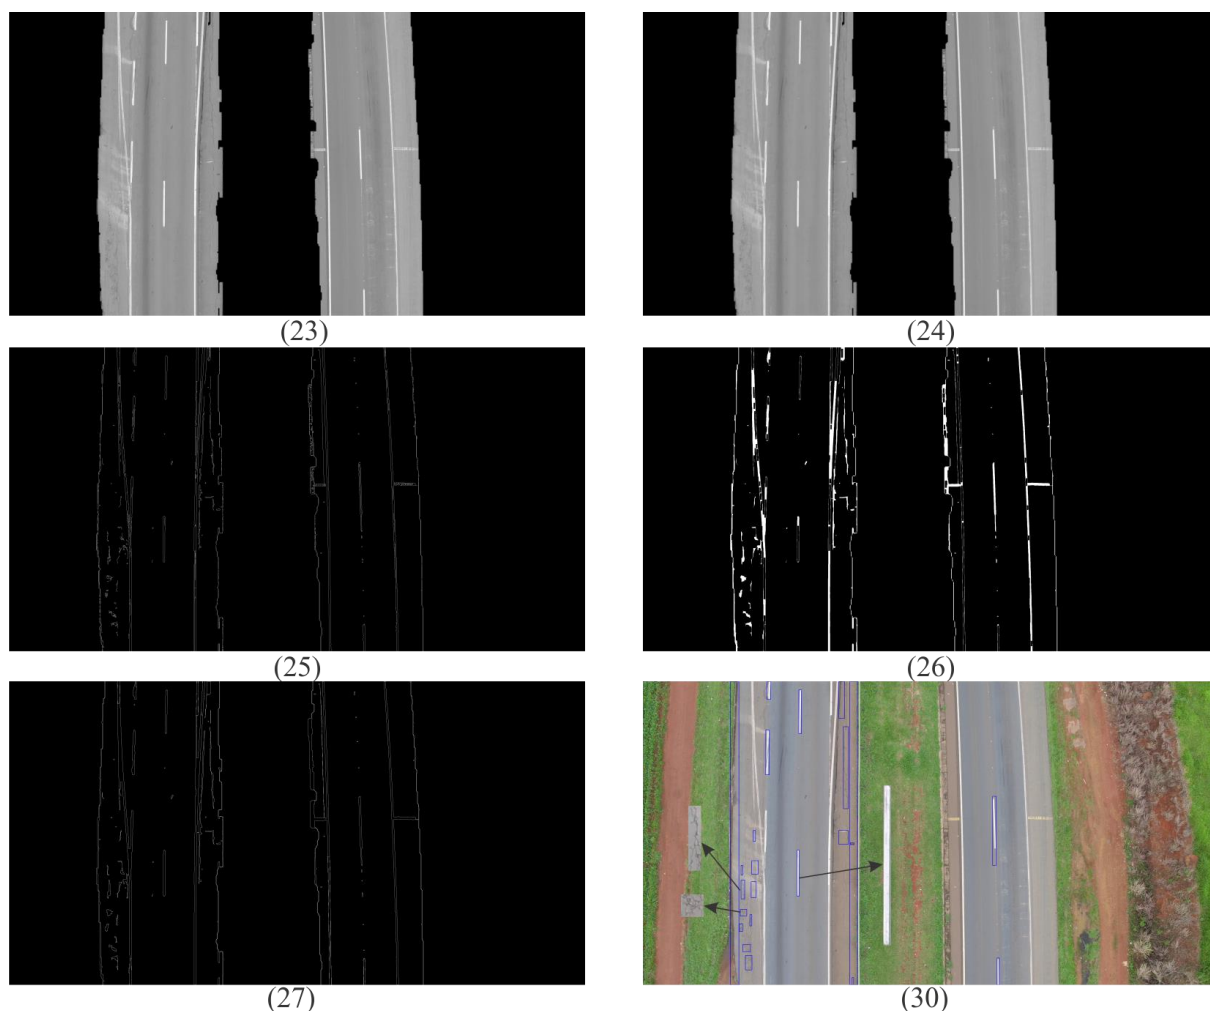


Figura 24 - Resultado da identificação de objetos. Cada número abaixo da figura representa a etapa no fluxograma do algoritmo apresentado na Figura 22.

Fonte: Autoria Própria.

3.8 CLASSIFICAÇÃO DE OBJETOS

Segmentado o objeto a partir de sua ROI, antes de sua classificação é preciso normalizar esse objeto e extrair características do mesmo. Desse modo se faz o redimensionamento do objeto (bloco 31) para uma dimensão de 256 x 64 pixels. Esta operação proporcionará a normalização dos objetos, pois devido a diferenças na altura de aquisição das imagens e diferentes dimensões entre os objetos, sem normalização, a etapa de classificação deles apresentará erros. Isto ocorre porque cada altura de aquisição gera um objeto diferente. Desta maneira, a normalização fará com que os objetos não sejam diferenciados pelo seu tamanho, mas sim por outras características, que é a próxima etapa a ser executada.

Na etapa seguinte são extraídas as características dos objetos de interesse redimensionados através do descritor HOG. Como o objeto possui dimensão 256 x 64, esse será o tamanho da janela do HOG. Com base no trabalho desenvolvido por Dalal e Triggs (2005), o parâmetro célula é definido com tamanho 8 x 8 pixels, o tamanho do bloco como sendo 16 x 16 (4 blocos de 8 células) e 9 orientações *bins*. Com esses parâmetros definidos, cada objeto encontrado na imagem terá o seu HOG calculado (bloco 32).

Antes da etapa de classificação é necessário definir as classes e selecionar um conjunto de objetos para treinamento do método de reconhecimento de padrões (bloco 33). Neste trabalho serão utilizadas 5 classes: setas, traços, carros, palavras e defeitos, que são os objetos de interesse a serem segmentados definidos na seção 3.7 do presente capítulo. A seleção do conjunto de treinamento é efetuada a partir de várias imagens, em ambientes distintos, utilizando o maior número de objetos possível.

Além disso, pelo fato de o HOG ser variável a direção do objeto (DALAL; TRIGGS, 2005), no procedimento de treinamento é efetuado três rotações nesses objetos: 90°, 180° e 270°. Com esta operação de rotação, problemas devido a direção dos objetos na etapa de classificação serão diminuídos. Isto é necessário porque nos voos do VANT os objetos não possuem uma direção fixa. Esse processo aumenta o conjunto de treinamento em 4 vezes, pois além da direção original do objeto, mais três direções são adicionadas ao conjunto de treinamento.

Após a seleção dos objetos de cada classe o algoritmo de classificação SVM é treinado (bloco 34). Essa etapa de separação de objetos e treinamento é executada de forma manual e separadamente da execução do algoritmo.

No fluxograma (Figura 22) existe uma seta que mostra a conexão entre o processo de cálculo do HOG (bloco 32) com os objetos selecionados (bloco 33). Essa conexão é somente demonstra como ocorre o procedimento de seleção e treinamento. Na execução do algoritmo esse procedimento não ocorre, sendo o fluxo do algoritmo redirecionado ao bloco 35. Assim antes da classificação de objetos são necessários alguns voos para adquirir imagens, segmentar objetos e assim ser possível treinar o classificador. Esses voos são necessários para que o algoritmo de segmentação seja testado e a partir de resposta positiva, efetuar a seleção manual dos objetos de cada classe para efetuar o treinamento do algoritmo.

Treinado o algoritmo, a classificação ocorre quando o HOG da ROI redimensionada é informada ao algoritmo (bloco 35). Classificado o objeto pelo algoritmo SVM, o mesmo é marcado na imagem original, indicando sua classe através do contorno do objeto com cor específica para sua classe (bloco 36). Com todos os objetos classificados (bloco 37), o algoritmo encerra e retorna ao bloco 2, reiniciando todo o processo. Ao término dessas operações o resultado obtido será o vídeo ou imagens contendo os objetos identificados e classificados na rodovia.

Finalizado o desenvolvimento das etapas a serem executadas para adquirir e processar imagens, testes em campo foram executados com os procedimentos descritos neste capítulo. Obtidas as imagens, estas foram submetidas ao algoritmo desenvolvido, permitindo segmentar objetos para treinar o algoritmo de reconhecimento de padrões e classificar os objetos detectados.

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados de testes efetuados com o algoritmo desenvolvido. Nestes testes é verificado a etapa de pré-processamento, segmentação de objetos sobre a rodovia para que estes sejam classificados posteriormente por método de reconhecimento de padrões.

As imagens adquiridas para o desenvolvimento deste trabalho foram obtidas em ambiente controlado e real. Por ambiente controlado entende-se área onde o voo possa ocorrer sem problemas adversos. Este ambiente controlado possui menor número de objetos se comparado com o ambiente real, além de ser possível inserir objetos artificiais. Como ambiente real é considerado uma rodovia em uso com fluxo de veículos.

Desta forma, após aquisição as imagens foram submetidas ao algoritmo desenvolvido. Inicialmente efetuou-se a avaliação do algoritmo referente a segmentação de rodovia e objetos.

Após testes bem-sucedidos com a segmentação, um conjunto de objetos segmentados pelo algoritmo foi selecionado para gerar um banco de imagens. Este repositório de imagens contém vários objetos de cada classe de objetos que se deseja identificar. Então, este conjunto de imagens é utilizado para treinar o algoritmo de reconhecimento, de forma que, a etapa de classificação dos objetos fosse executada. Também foram efetuados testes de tempo de resposta com o algoritmo, verificando o tempo de processamento de cada etapa.

4.1 TESTES DE SEGMENTAÇÃO DE OBJETOS

Para verificar o funcionamento do algoritmo referente a segmentação de objetos, foram realizados voos em ambiente controlado e ambiente real para adquirir imagens. Os primeiros voos de teste foram executados em ambiente controlado com a adição de objetos artificiais neste ambiente. Estes voos foram necessários para que além de validar o algoritmo, ser necessário gerar um banco de imagens e assim ser possível treinar e testar o algoritmo de reconhecimento de padrões.

4.1.1 TESTES EM AMBIENTE CONTROLADO

Os primeiros testes foram realizados em ambiente com menor número de objetos com o objetivo de avaliar o desempenho do algoritmo, além de efetuar voos em um ambiente mais seguro. O local escolhido foram os estacionamentos e ruas internas do campus Neville da UTFPR, localizado na cidade de Curitiba - PR (latitude 25°30'22.83"S e longitude 49°18'59.85"O).

Entretanto, muitas de suas marcações estavam danificadas ou não seguiam as regras do Departamento Nacional de Infraestrutura e Transporte (DNIT). Assim, foram confeccionadas algumas setas, em escala reduzida de duas vezes, a partir de regras propostas pelo DNIT que estão no Manual de sinalização rodoviária (DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTE; EXECUTIVA; RODOVIÁRIAS, 2010). As setas foram posicionadas sobre o pavimento e os voos de aquisição foram efetuados.

Para os primeiros testes, o ambiente a ser monitorado foi sobrevoado de forma manual, ou seja, o piloto selecionou partes de interesse e voou sobre estas partes utilizando o controle para direcionar a aeronave e o aplicativo para visualizar e capturar as imagens. Neste modo de voo manual as imagens foram adquiridas em formato de vídeo, proporcionando um voo com maior aquisição de imagens. A Figura 25 apresenta algumas das imagens obtidas no ambiente de teste. Os retângulos azuis no entorno dos objetos indicam que estes foram identificados e segmentados pelo algoritmo. A altura dos voos foi configurada para 30 metros e a velocidade média ajustada para 30 km/h.



Figura 25 - Testes de segmentação de rodovia e objetos em ambiente controlado. Retângulos em azul indicam objetos identificados

Fonte: Autoria Própria.

Além de adquirir imagens no formato de vídeo, foi utilizado o aplicativo Pix4Dcapture para adquirir imagens e gerar o ortomosaico do ambiente através do software Pix4D desktop. Na aquisição das imagens, foi utilizada uma altura de 40 metros. Foram adquiridas 94 fotos de um

local com dimensões de 124 x 57 metros, sendo esse voo executado automaticamente. Neste modo de voo, o piloto define a área a ser sobrevoada e pode intervir a qualquer momento. As Figura 26 (a) e (b) são algumas das 94 imagens adquiridas para gerar o ortomosaico. A Figura 26 (c) apresenta o ortomosaico gerado, sendo sua dimensão 15982 x 12667 pixels. Essa imagem também foi submetida ao algoritmo desenvolvido e os objetos identificados foram marcados em azul. Para melhor visualização, a Figura 26 (d) apresenta uma ampliação da Figura 26 (c).

Nas imagens processadas é possível verificar alguns retângulos azuis sem nenhum objeto em seu interior. Isso é um erro de segmentação. Na etapa de detecção de bordas, devido ao princípio do algoritmo de Canny utilizar a diferença de contraste para encontrar as bordas dos objetos, nesses pontos, o algoritmo encontrou estas diferenças no contraste, identificando então, uma borda do objeto.

Na Figura 25 esses erros são menos recorrentes, onde estes ocorreram em locais onde haviam sombras. Já nos resultados apresentados na Figura 26, esse erro ocorreu em maior número pelo fato de existir várias regiões apresentando asfalto seco e molhado, sendo esta diferença uma transição de contraste. Devido a esta transição o detector de bordas identifica essa alteração como sendo um objeto.

Esse problema tem solução complexa, pois na definição dos parâmetros do algoritmo de Canny se os limites necessários para o funcionamento do algoritmo forem definidos com baixo valor o algoritmo ficará sensível a mínima variação encontrada. Então, vários pontos que não são de interesse podem ser identificados. Por outro lado, se o limite for definido com um valor alto, vários objetos de interesse não serão identificados. Assim, vários testes foram efetuados para definir esses limites de forma que a maior parte dos erros possam ser tratados, sem perder a capacidade de encontrar objetos de interesse.

Após testes positivos em ambiente controlado, imagens em ambiente real foram adquiridas com o objetivo de verificar o funcionamento do algoritmo com estas imagens.

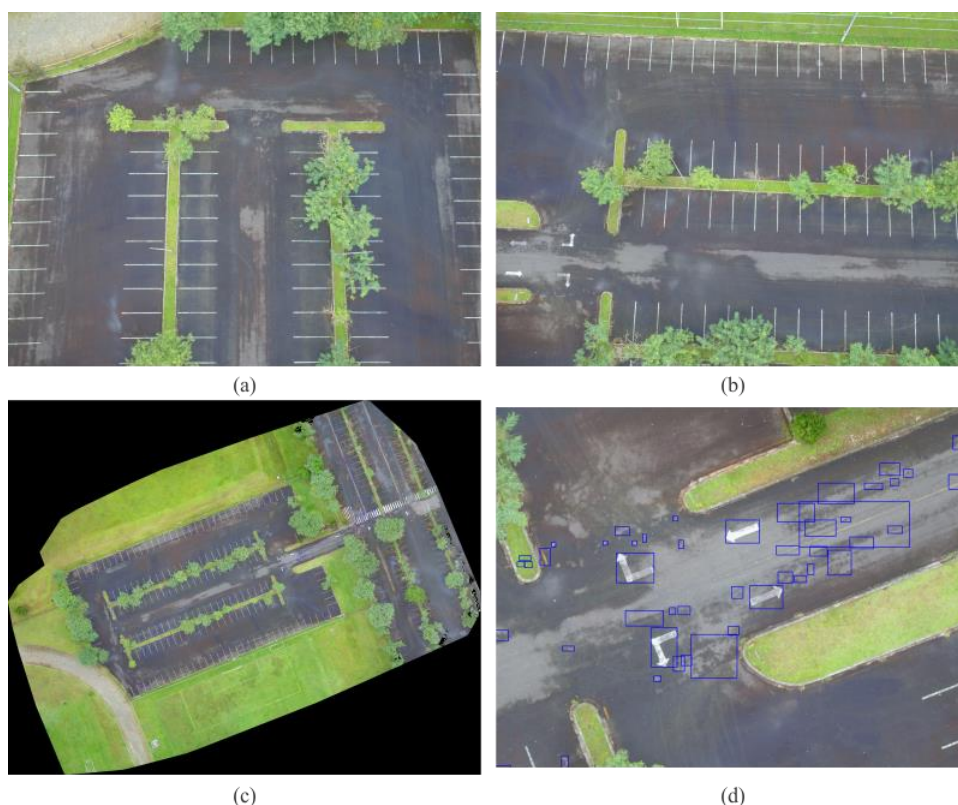


Figura 26 - Geração de ortomosaico. (a) e (b) são imagens adquiridas para gerar o ortomosaico. (c) ortomosaico gerado com os objetos com os objetos identificados em azul. (d) ampliação de um ponto da imagem (c).

Fonte: Autoria Própria.

4.1.2 TESTE EM AMBIENTE REAL

Como o trabalho apresentado é executado em parceria com a concessionária de rodovias Triunfo Concebra, foram solicitados pontos de interesse a serem monitorados por parte da concessionária. Então, os seguintes pontos de interesse foram definidos: um em Goiânia - GO na rodovia BR-153 km 493 (latitude $16^{\circ}44'51.82''S$ e longitude $49^{\circ}14'27.46''O$), e outro em Goianápolis – GO BR-060 no km 107 (latitude $16^{\circ}26'17.79''S$ e longitude $49^{\circ}1'6.64''O$). Estes locais são o ambiente real utilizado nesta etapa, em que é monitorado uma rodovia com fluxo de veículos.

Para os testes em ambiente real, os voos foram executados com altura de 80 metros na BR-060 e 100 metros na BR-153, ambos com velocidade média de 60 km/h. Também foi executado um voo a partir do aplicativo Pix4Dcapture. Entretanto, este voo teve pouco espaço monitorado devido a condições climáticas adversas no local de voo ao qual havia sido autorizado a operação.

Neste ambiente, além de identificar e segmentar marcações horizontais, mais 3 objetos de interesse foram incluídos, sendo estes carros, escritas e defeitos no pavimento.

Após aquisição, as imagens foram processadas para que os objetos de interesse fossem identificados e segmentados. Desta forma, a Figura 27 apresenta os resultados de segmentação de objetos obtidos em ambiente real.



Figura 27 - Testes de segmentação de rodovia e objetos em ambiente real. Retângulos azuis indicam objetos identificados.

Fonte: Autoria Própria.

Assim como nos testes em ambiente controlado, alguns erros de segmentação podem ser notados na Figura 27. Estes erros possuem a mesma origem dos erros em ambiente controlado.

Entretanto, em ambiente real a configuração dos limites se torna mais crítica, pois defeitos no pavimento podem apresentar leves alterações na imagem. Assim, a configuração do limite inferior no algoritmo de detecção de bordas pode ocasionar na não identificação dessas defeitos, o que limitaria o algoritmo desenvolvido.

Com os testes de segmentação de objetos efetuados com sucesso, vários objetos segmentados de cada classe definida no capítulo 3 seção 3.8 foram selecionados. Isso é efetuado para criar um banco de imagens para treinamento e teste do algoritmo de reconhecimento de padrões.

O repositório de imagens é gerado da seguinte forma: após os testes de segmentação, vários objetos são armazenados para análise. Como grande parte das imagens foram adquiridas em formato de vídeo, a cada quadro processado, vários objetos são extraídos das imagens.

Extraídos os objetos, estes são selecionados manualmente um a um para cada classe definida. Esse processo é efetuado de forma manual para garantir que os objetos utilizados, tanto no treinamento, quanto no teste, sejam da classe que está sendo treinada.

Além disso, a análise manual permite que seja escolhido os objetos mais distintos de cada classe, fazendo com que o treinamento do algoritmo seja robusto. Essa robustez é necessária para

que o classificador possa distinguir com facilidade os objetos de interesse, mesmo com variações de tamanho e luminosidade no objeto.

4.2 TREINAMENTO E TESTE DO SVM

Após gerado o repositório de imagens para cada classe de objetos através da segmentação pelo algoritmo desenvolvido, as imagens constantes neste banco foram utilizadas para treinamento e teste do método de reconhecimento de padrões. A Tabela 1 apresenta a quantidade de objetos utilizados no treinamento de cada classe e a Figura 28 apresenta alguns dos objetos de cada classe.

Como é utilizado para extrair as características dos objetos segmentados o descritor HOG e devido a este ser sensível à direção, durante o voo, os objetos na rodovia não possuem uma direção fixada em devidos momentos, como por exemplo, curvas e retornos.

Assim, em cada objeto, foi executada uma rotação de 90°, 180° e 270° para que o classificador fosse treinado com amostras em várias direções. Então, a quantidade de objetos para treinamento tem um acréscimo em 4 vezes devido a estas rotações executadas. Isto é efetuado para melhorar a precisão do classificador, incrementando a quantidade de amostras utilizadas no treinamento e as características de cada classe de objetos.

Tabela 1 - Quantidade de objetos por classe utilizado para treinamento e teste e quantidade total após a rotação de cada objeto.

Classe	Quantidade de Objetos (sem rotação)	Quantidade de Objetos (com rotação)
Carro	124	496
Seta	312	1.248
Traço	565	2.260
Escrita	216	864
Defeito	427	1.708
Total	1.644	6.576

Fonte: Autoria Própria




Figura 28 - Exemplo de objetos para treinamento e teste. (a) Carros, (b) Traços, (c) Escrita, (d) Setas, (e) defeitos.
 Fonte: Autoria Própria.

No processo de treinamento ficou definido que 70% das amostras serão utilizadas para treinar o método e o restante será utilizado no teste de desempenho do SVM. Como *kernel* para separação ótima do hiperplano foi escolhido o modelo linear, pois em testes efetuados este *kernel* apresentou os melhores resultados para o problema de classificação apresentado neste trabalho.

Finalizado o treinamento é efetuado o teste de desempenho do SVM com os 30% de objetos restantes do conjunto de imagens. Como no teste tem-se conhecimento da classe de cada objeto submetido para classificação, a partir dos resultados é construída uma matriz de confusão, avaliando o desempenho do classificador. Essa matriz é apresentada na Tabela 2, onde as amostras classificadas corretamente com a sua classe estão na diagonal dessa matriz. A partir da matriz de confusão a Tabela 3 foi construída, apresentando a proporção de classificações positivas geral e de cada classe.

Tabela 2 - Matriz de Confusão para o classificador SVM + HOG treinado. A linha diagonal formada indica as amostras classificadas corretamente.

	Carro	Seta	Traço	Escrita	Defeito	
Carro	144	0	0	0	0	Previsão
Seta	0	366	4	12	16	
Traço	0	8	678	0	4	
Escrita	0	0	0	248	0	
Defeito	8	0	0	0	492	
	Verdadeiro					

Fonte: Autoria Própria.

Tabela 3 - Desempenho do classificador treinado para cada classe e desempenho total do classificador SVM com características HOG dos objetos.

Classe	Classificação Positiva (%)
Carro	94,73
Seta	97,87
Traço	99,41
Escrita	95,38
Defeito	96,12
Geral	97,37

Fonte: Autoria Própria.

De forma geral, o classificador SVM apresentou resultado satisfatório, fornecendo 97,37% de acertos para o conjunto de objetos de teste. Referente ao desempenho separado das classes, a classe contendo carros foi a que apresentou menor taxa de acerto, alcançando 94,73% de classificações corretas. Este desempenho inferior pode ser ocasionado devido a diversidade dos objetos a serem classificados. Como cada carro apresenta diferentes formatos e cores, cada um apresentará características diferentes, dificultando o processo de separação ótima do hiperplano do SVM.

Além disso, a classe carros possuía o menor número de objetos utilizados para treinamento, pois no processo de segmentação de veículos, como os mesmos possuem movimento nas imagens, em vários casos, além dos veículos, outros objetos são segmentados em conjunto. Então, a tarefa de separar veículos segmentados para o processo de treinamento e teste se torna complexa, diminuindo a quantidade de objetos para treinamento.

Finalizado a etapa de treinamento e teste do SVM a partir do banco de imagens gerado através da segmentação de objetos pelo algoritmo desenvolvido, testes de classificação de objetos segmentados foram executados em imagens adquiridas em ambiente controlado e real.

4.3 TESTES COM O ALGORITMO DESENVOLVIDO

Após efetuado o treino e teste do método de reconhecimento de padrões, o algoritmo desenvolvido foi executado para segmentar e identificar de forma automática objetos de interesse em uma rodovia. O desempenho do algoritmo foi testado em aproximadamente 2 horas de vídeos adquiridos entre ambiente controlado e real, além de testes com mosaicos de imagens.

As Figura 29 (a) e (b) apresentam os resultados fornecidos pelo algoritmo para os vídeos adquiridos em ambiente controlado. Cada classe é identificada por uma cor, onde setas são tingidas com a cor verde, carros com azul, traços com vermelho, palavras com amarelo e defeitos com magenta.

É possível verificar nessas imagens alguns erros de segmentação, onde pequenas variações na coloração do pavimento ou sombras são classificadas como defeitos ou setas. Esse erro é mais recorrente na Figura 29 (c) devido as diferenças entre asfalto úmido e seco, que são identificadas como vários objetos.




Figura 29 - Testes de identificação em ambiente controlado. (a) e (b) são frames de vídeos que foram adquiridos. (c) é o resultado de identificação do ortomosaico apresentado na Figura 26 (c). Objetos marcados em verde foram identificados como setas, em vermelho traços, azul carros e magenta defeitos.

Fonte: Autoria Própria.

O algoritmo também foi executado com imagens do ambiente real e as Figuras Figura 30 e Figura 31 apresentam os resultados obtidos. Nestas imagens foi verificado que alguns objetos não são identificados. Este erro acontece pela condição executada pelo algoritmo na etapa 28 (Figura 22), onde alguns objetos podem ser desconsiderados devido a sua área estar fora do limite estabelecido.

Esse erro de segmentação pode ser ocasionado devido ao movimento dos objetos na rodovia, ocorrendo sobreposição ou a união de dois objetos. Esta união pode ocorrer na etapa em que é executada a operação morfológica de fechamento (bloco 26 do fluxograma). A Figura 32 (a) apresenta um exemplo de objeto conectado a outro após a operação morfológica executada. Esse problema poderia ser corrigido com a alteração do elemento estruturante. Entretanto, em testes efetuados, essa alteração faz com que vários objetos indesejados são considerados pelo algoritmo, o que diminui o desempenho do algoritmo.

Já o problema de sobreposição de objetos não foi solucionado e como se tem dois objetos de classes distintas como objeto único, o erro de classificação será evidente. Esse erro pode ser visualizado na Figura 32 (b). Porém, como os objetos sempre estão em movimento, será somente em alguns momentos do vídeo que esses erros acontecerão, não gerando problemas de precisão no algoritmo.



Figura 30 - Testes de classificação em ambiente real. Objetos marcados em verde foram identificados como setas, em vermelho traços, azul carros, palavras em amarelo e magenta defeitos.

Fonte: Autoria Própria.

Referente ao mosaico gerado, é possível verificar que o fluxo de veículos pode ocasionar erros na geração deste, como pode ser visualizado na Figura 31. No entanto, é possível verificar que o algoritmo apresentou um bom resultado, sendo que, vários pontos foram marcados como defeito na rodovia, sendo que, estes pontos eram manchas de óleo na pista.

O algoritmo identificou também uma seta defeituosa neste mosaico e a classificou como um defeito. Com este resultado, é possível verificar o potencial do algoritmo para identificação de pontos de interesse da via também em mosaico de fotos.




Figura 31 - Teste de classificação de ortomosaico gerado de ambiente real com área de 0.0042 km². Objetos marcados em verde foram identificados como setas, em vermelho traços, azul carros, palavras em amarelo e magenta defeitos. Fonte: Autoria Própria.

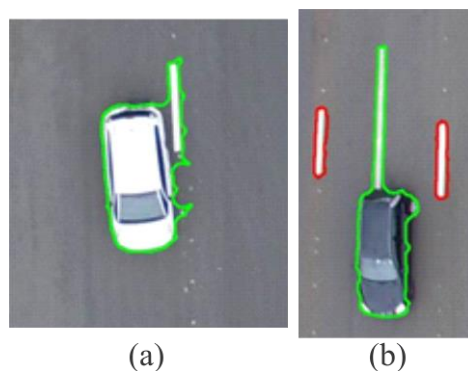


Figura 32 - Erro de segmentação de objetos. (a) Objetos conectados. (b) Sobreposição de objetos.

Fonte: Autoria Própria.

Outro problema durante o desenvolvimento do algoritmo é referente a segmentação de rodovia em locais com interseções e construções nas laterais. Dado que o objetivo é segmentar a rodovia, foram definidos limites para que construções laterais fossem removidas. Em consequência, em locais com interseções entre rodovias ou rodovia e estacionamentos laterais, em alguns quadros do vídeo, é possível verificar que nenhum objeto é identificado, pois nesse momento, aquele segmento de rodovia foi removido.

Isso pode ocorrer pelo fato do segmento identificado se unir a outras regiões durante a operação morfológica de abertura, ou até mesmo na etapa de segmentação por cores, devido a semelhança destas construções com a área pavimentada.

Assim, na etapa de verificação da geometria desse segmento, a parte que efetua a separação dos maiores segmentos (bloco 15 no fluxograma) considerará que somente um segmento de rodovia, pois a diferença entre o primeiro e o segundo maior segmento será grande o suficiente para que o segundo segmento seja descartado. Assim, as outras áreas serão removidas, ocasionando um erro. Esse erro pode ser visualizado na Figura 33.

Entretanto, este problema se repetiu mais vezes em imagens capturadas com a câmera do VANT posicionada a menos que 90° . Como a maior parte das imagens são obtidas com a câmera em 90° com a superfície, esse problema é minimizado com a alteração no procedimento de aquisição das imagens, não sendo necessário, alterações no algoritmo.




Figura 33 – Erro na segmentação de asfalto. (a) Imagem original, (b) Segmentação por cor, (c) Pavimento segmentado após análise dos segmentos selecionados como sendo pavimento.

Fonte: Autoria Própria.

4.4 TESTES DE TEMPO DE RESPOSTA

Referente ao tempo de resposta do algoritmo, este foi testado em sistema operacional Windows e Ubuntu com o sistema computacional apresentado no capítulo 3, seção 3.4. Durante os testes foi verificando o tempo de execução das etapas de pré-processamento, segmentação de objetos e classificação. Assim, foram analisados dois casos, sendo o primeiro o tempo de processamento de frames de vídeo e o segundo o tempo de processamento de um ortomosaico, todos estes sendo executados pela CPU.

Para os testes foram utilizados o mesmo conjunto de vídeos em cada sistema operacional. Assim as tabelas Tabela 4 e Tabela 5 apresentam o tempo de processamento de frames e do ortomosaico gerado em ambiente controlado em cada sistema operacional.

A análise do tempo de processamento somente do ortomosaico de ambiente controlado foi escolhida pelo fato de este ser maior que o mosaico gerado em ambiente real. Além disso, como esse tamanho não é constante, a cada mosaico gerado, se terá um tamanho e consequentemente um tempo de processamento diferente. O tempo total apresentado nas tabelas considera o tempo de ler e escrever a imagem no disco, enquanto os tempos apresentados de forma isolada em cada operação, não considera estas etapas.

Tabela 4 - Tempo de processamento pela CPU de cada etapa e total de um frame de vídeo. Na tabela, "s" significa segundos.

Operação	Tempo Windows (s)	Tempo Ubuntu (s)
Pré-Processamento	0,08	0,025
Segmentação Objetos	0,56	0,091
Classificação um objeto	0,0005	0,0008
Tempo total	1,54	0,15

Fonte: Autoria Própria.

Tabela 5 - Tempo de processamento de cada etapa e total no ortomosaico apresentado na Figura 26 (c). Na tabela, "s" significa segundos.

Operação	Tempo Windows (s)	Tempo Ubuntu (s)
Pré-Processamento	1,93	0,49
Segmentação Objetos	26,83	2,19
Classificação um objeto	0,0002	0,00003
Tempo total	88,97	16,19

Fonte: Autoria Própria.

Também foram executados testes de processamento utilizando a GPU ao invés da CPU. No entanto estes testes foram executados somente no sistema operacional Ubuntu, pois a API OpenCV apresentou problemas no ambiente Windows. Assim, a Tabela 6 apresenta o tempo de processamento de um frame em cada etapa, utilizando a GPU para executar algumas etapas.

Verifica-se que não houve grande ganho de desempenho. Isto pode ter sido ocasionado por grandes trocas de contexto entre CPU e GPU, pois não são todas as funções da API OpenCV que estão implementadas para serem executadas pela GPU.

Assim, a cada chamada da GPU é necessário transferir toda a imagem da memória primária para a memória de vídeo. A operação de transferência de informações apresenta grande custo computacional, ocasionando perda de desempenho.

Entretanto, se analisado as operações de forma isolada é possível verificar que o uso da GPU poderá proporcionar respostas mais ágeis se todas as operações forem executadas utilizando este tipo de processador.

Referente a testes de tempo de resposta de processamento de ortomosaico na GPU, estes não foram possíveis, pois devido a grande dimensão da imagem, o hardware utilizado não possuía a memória de vídeo suficiente para executar as tarefas com a imagem completa.

Tabela 6 - Tempo de processamento de um frame utilizando a GPU.

Operação	Tempo (s)
Pré-Processamento	0,20
Segmentação Objetos	0,073
Classificação um objeto	0,00004
Tempo total	0,17

Fonte: Aatoria Própria.

A grande discrepância entre o tempo levado pelo sistema Windows e Ubuntu ocorre pela maneira de como cada sistema operacional gerencia sua memória e tempo de processador. Se analisado as tabelas Tabela 4 e Tabela 5, verifica-se que o sistema operacional Ubuntu executa o mesmo algoritmo em média com 80% menos tempo.

A partir dos resultados obtidos é possível verificar que o algoritmo desenvolvido pode fornecer respostas rápidas e precisas tanto para vídeos como para grandes imagens. Desta forma, este algoritmo poderá auxiliar as equipes que efetuam e gerenciam a manutenção de rodovias a efetuarem o planejamento de manutenções de forma mais precisas e com execução mais ágil, permitindo melhor seleção de pontos críticos que devem ser reparados.

5 CONCLUSÃO E TRABALHOS FUTUROS

Rodovias são uma das vias de tráfego amplamente utilizadas para locomoção de pessoas e cargas não somente no Brasil, mas também em vários outros países. Diante desse fato, as condições da malha rodoviária, desde o pavimento até a sinalização, devem possuir bom estado de conservação para que seus usuários possam usufruir dessa malha sem problemas adversos e com segurança. A partir da importância na manutenção dessa via, técnicas que auxiliem na identificação de problemas em rodovias de modo automático são pesquisadas por vários grupos com a intenção de diminuir o tempo de serviço e deslocamento de colaboradores, além de aumentar a precisão e possuir um registro mais amplo das informações coletadas.

Pelo fato de atualmente grande parte das inspeções serem efetuadas visualmente e em pequenas áreas, este trabalho propôs uma metodologia para monitorar rodovias através de sensoriamento remoto. Uma das técnicas de sensoriamento remoto que está ganhando grande destaque é o VANT com câmera acoplada, que é utilizada para adquirir imagens da rodovia a ser inspecionada. O uso desta tecnologia permite a varredura de grandes áreas com pouco tempo de trabalho e sem interrupção do fluxo da via a ser monitorada. Em conjunto ao uso do VANT para adquirir imagens, foram utilizadas técnicas para processar imagens adquiridas, com o objetivo de extrair informações destas imagens. O objetivo de processar essas imagens é auxiliar equipes de manutenção de rodovias a executarem um trabalho mais preciso, diminuindo a necessidade de inspeção *in situ*.

Na primeira parte deste trabalho foram especificados requisitos referentes a aeronave e a câmera acoplada. A partir destes requisitos uma busca por um VANT comercial que atendesse aos requisitos exigidos foi efetuada. Nesta busca a RPAS que atendeu aos requisitos de voo com tempo mínimo de 15 minutos, câmera acoplada com peso máximo de 600 g e sistemas de segurança mínimos foi a aeronave Inspire 1 RAW que proporciona voos com tempo máximo de 18 minutos com uma câmera de 16 Mpixels acoplada.

No desenvolvimento do trabalho, as regras para uso de VANT no Brasil estavam sendo desenvolvidas pelos órgãos responsáveis. Assim, nos primeiros testes efetuados foram seguidas as recomendações contidas na RBAC-E nº 94 disponibilizada para consulta pública pela ANAC em 2015. Após maio de 2017, o uso comercial de VANTs foi regulamentado no Brasil pela ANAC através da RBAC-E nº 94. Em conjunto com essas regras, o DECEA disponibilizou o sistema

SARPAS, que é utilizado para solicitação do espaço aereo. Neste trabalho, todos os voos executados seguiram as recomendações exigidas pela ANAC e DECEA.

Para o procedimento de obter imagens, foi desenvolvido um *check-list* para que todo voo executado ocorresse com segurança. Com isso, os primeiros testes foram executados em ambiente controlado, sendo este ambiente os estacionamentos e ruas internas do campus Neville da UTFPR, situado em Curitiba – PR. Este ambiente oferecia segurança ao voo executado para que esse *check-list* fosse desenvolvido e testado. O ambiente do Campus Neville também foi utilizado para as primeiras aquisições de imagens, pois este ambiente oferecia menor número de objetos, além de permitir a inclusão de objetos artificiais para testes. Como as marcações horizontais demarcadas na área pavimentada do Campus não estavam de acordo com as regras propostas pelo DNIT, foram confeccionadas algumas setas que obedeciam estas regras. Com estas setas, foram executados testes de classificação de objetos.

Após resultados positivos em ambiente controlado, testes em ambiente real foram executados. Neste caso ambiente real se entende por uma rodovia com fluxo de veículos. Então, pontos de interesse foram solicitados a concessionária Triunfo Concebra para que estes fossem monitorados. Desta forma, a equipe da concessionária sugeriu um ponto em Goiânia - GO na rodovia BR-153 km 493, e o outro em Goianópolis – GO BR-060 no km 107. Os voos executados em ambiente real seguiram os mesmos procedimentos do ambiente controlado, permitindo então, um voo com segurança.

Antes de iniciar o desenvolvimento do algoritmo de processamento, um estudo sobre representação de imagens aéreas de rodovias foi efetuado. Com este estudo, foi possível compreender como a estrutura de uma rodovia e seus componentes são apresentados em imagens aéreas. Então, a partir do conhecimento em detalhes de como uma rodovia aparenta em uma imagem aérea, iniciou-se o desenvolvimento do algoritmo de processamento, de forma que fosse priorizado as características da rodovia e seus componentes.

Referente o processamento das imagens adquiridas a partir da câmera acoplada a RPAS, foi desenvolvido um algoritmo que está dividido em três partes. A primeira parte é responsável por efetuar o pré-processamento na imagem, sendo que este processamento, consiste em segmentar a rodovia da imagem. Assim é formando uma imagem que contém somente a rodovia, retirando partes que não são de interesse, como áreas com vegetação. A segunda parte do algoritmo consiste em identificar e segmentar os objetos contidos na rodovia. Esta etapa de identificação de objetos utiliza como entrada, a imagem resultante da etapa de pré-processamento, ou seja, a imagem que possui somente a rodovia. Após segmentados os objetos da rodovia, são extraídas características

destes objetos através do descritor HOG para que estes objetos sejam classificados pelo método de reconhecimento de padrões SVM. Para a classificação, foram definidas 5 classes, sendo estas, carro, setas, traços, escritas e defeitos.

O algoritmo desenvolvido foi testado em aproximadamente 2 horas de vídeos e em dois ortomosaicos. Para o treinamento e teste do algoritmo de classificação SVM, foram utilizadas 6.576 amostras, onde 70% destas amostras foram utilizadas para treinar o algoritmo e o restante utilizada para verificar o desempenho do algoritmo. No teste de desempenho, o SVM proporcionou taxa de acerto de 97,37%. A classificação de objetos é utilizada para identificar de forma mais rápida e precisa possíveis problemas. Desta forma, é possível executar ações com maior agilidade, permitindo as equipes que gerenciam a rodovia, deslocar a equipe correta para a resolução do problema identificado.

Nos testes efetuados com o algoritmo, também foram verificados os tempos de processamento necessários para que cada imagem seja processada. Desta maneira, testes foram efetuados em sistema operacional Windows e Ubuntu. No sistema operacional Windows, o algoritmo precisou de 1,54 s para processar 1 *frame* do vídeo, enquanto no sistema operacional Ubuntu, esse tempo foi de apenas 0,15 s. A grande diferença no tempo de processamento utilizando o mesmo sistema computacional diferindo apenas, o sistema operacional, é dado pelo fato de cada sistema gerenciar de forma diferente o processador e a memória principal.

Mesmo apresentando resultados positivos, o algoritmo proporcionou respostas erradas em alguns pontos durante a sua execução. Um dos erros ocorreu no pré-processamento, onde na análise da geometria do segmento de rodovia, em vias duplicadas com construções laterais, um dos segmentos de rodovia era removido. Esse erro acontecia devido a um dos segmentos ter se conectado a estacionamentos laterais. Também foram notados erros devido a execução das operações morfológicas para melhorar a identificação dos objetos. Este erro ocorre pois em alguns objetos se unem após a execução da operação morfológica de fechamento proporcionando assim, erros na classificação destes objetos. Outro problema ocorrido referente a segmentação, como a rodovia possui vários objetos em movimento, em vários momentos, alguns objetos se sobrepõem. Quando isto acontece, os objetos são segmentados em conjunto, o que também pode ocasionar em uma classificação errada.

Mesmo com estes erros, a ferramenta desenvolvida neste trabalho fornece informações importantes da malha rodoviária que se deseja analisar, sendo o principal ponto a detecção de defeitos no pavimento. Além disso, a não identificação ou classificação errônea de marcações horizontais, pode indicar problemas nestas marcações, como por exemplo, pintura desgastada.

Com a metodologia proposta neste trabalho é possível identificar pontos de interesse de instituições públicas, como por exemplo o DNIT e a Agência Nacional de Transportes Terrestres (ANTT) e privadas, como por exemplo, concessionárias de rodovias e construtoras de pavimentação. As técnicas propostas nesta dissertação podem ser empregadas em conjunto com análise de fluxo em imagens para indicar acidentes e desastres naturais a partir das imagens adquiridas pelo VANT, proporcionando a análise de fluxo, vasta gama de aplicações.

A partir dos resultados apresentados neste trabalho, o uso desta metodologia por equipes de gerenciamento de obras pode otimizar o deslocamento de colaboradores, permitindo o reparo de defeitos de forma ágil e precisa, diminuindo assim, custos e realocando grupos de trabalho para áreas com maior urgência.

5.1 TRABALHOS FUTUROS

A partir do trabalho desenvolvido, bem como os resultados obtidos, alguns trabalhos futuros podem ser executados para melhorar ou incrementar a metodologia proposta. Referente a segmentação de rodovia, estudos podem ser desenvolvidos para aprimorar a técnica desenvolvida neste trabalho e melhorar os resultados obtidos como, por exemplo, a aplicação de diferentes técnicas, como o uso de técnicas de reconhecimento de padrões. Esta técnica não foi empregada neste trabalho devido a dificuldades em separar partes que contém somente rodovia e outras partes de interesse. Com este problema na separação dos pontos de interesse, o método de reconhecimento de padrões apresentou resultados inferiores ao método utilizado. Entretanto, com um estudo mais aprofundado na resolução do problema de separação de pontos de interesse em conjunto com técnicas de reconhecimento de padrões, resultados mais precisos podem ser alcançados. O algoritmo desenvolvido também pode ser aprimorado para gerar relatórios, informando de maneira georeferenciada, os pontos com defeitos identificados. Neste aprimoramento pode ser adicionado também uma função que fornecerá ao usuário o tamanho dos defeitos encontrados, além da área de marcações horizontal identificada.

Outro trabalho que pode ser desenvolvido é a aplicação de redes neurais convolucionais na classificação de objetos segmentados. Como esse método de reconhecimento de padrões está sendo amplamente empregado em várias áreas, o seu uso neste problema pode oferecer melhores resultados. Um trabalho que também pode ser desenvolvido para verificar possíveis melhorias na classificação de objetos é aplicar o uso de outros descritores além do HOG.

Relacionado a identificação de defeitos em pavimento e marcações horizontais é possível desenvolver um trabalho que melhore a extração de defeitos no pavimento e análise de qualidade de marcações horizontais, proporcionando maior agilidade no monitoramento de rodovias.

REFERÊNCIAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **REQUISITOS GERAIS PARA VEÍCULOS AÉREOS NÃO TRIPULADOS E AEROMODELOS**. Disponível em: <<http://www.anac.gov.br/participacao-social/audiencias-e-consultas-publicas/audiencias/2015/aud13/anexoi.pdf>>. Acesso em: 1 out. 2015.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Requisitos Gerais para Aeronaves Não tripuladas de uso CivilBrasil**, 2017a. Disponível em: <http://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94-emd-00/@@display-file/arquivo_norma/RBACE94EMD00.pdf>

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Regras de ógãos brasileiros sobre operação de drones**. Disponível em: <<http://www.anac.gov.br/assuntos/paginas-tematicas/drones/regras-de-todos-os-orgaos-brasileiros-sobre-operacao-de-drones>>. Acesso em: 5 maio. 2017b.

AWANGE, J. L.; KYALO KIEMA, J. B. Fundamentals of Photogrammetry. In: **Environmental Geoinformatics: Monitoring and Management**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 157–174.

BAUMGARTNER, A. et al. Automatic Road Extraction Based on Multi Scale, Grouping, and Context. **Photogrammetric Engineering and Remote Sensing**, v. 65, n. 7, p. 777–785, 1999.

BEYERER, J.; PUENTE LEÓN, F.; FRESE, C. Color. In: **Machine Vision**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016a. p. 163–202.

BEYERER, J.; PUENTE LEÓN, F.; FRESE, C. Segmentation. In: **Machine Vision**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016b. p. 553–605.

BEYERER, J.; PUENTE LEÓN, F.; FRESE, C. Morphological Image Processing. In: **Machine Vision**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016c. p. 607–647.

CAPONETTI, L.; CASTELLANO, G. Image Representation Using Java. In: **Fuzzy Logic for Image Processing**. Cham: Springer International Publishing, 2017a. p. 3–13.

CAPONETTI, L.; CASTELLANO, G. Java for Image Processing. In: **Fuzzy Logic for Image**

Processing. Chan: Springer International Publishing, 2017b. p. 65–81.

CHAMBON, S.; MOLIARD, J. M. Automatic Road Pavement Assessment with Image Processing: Review and Comparison. **International Journal of Geophysics**, v. 2011, p. 1–20, 2011.

CHEN, Y. M.; DONG, L.; OH, J.-S. **Real-Time Video Relay for UAV Traffic Surveillance Systems Through Available Communication Networks.** 2007 IEEE Wireless Communications and Networking Conference. **Anais...IEEE**, 2007Disponível em: <<http://ieeexplore.ieee.org/document/4224730/>>

CHOPADE, K.; GURU, S. K. A Survey: Unmanned Aerial Vehicle for Road Detection and Tracking. **International Journal of Innovative Research in Computer and Communication Engineering**, v. 3, n. 10, p. 10761–10766, 2015.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.

CONFEDERAÇÃO NACIONAL DO TRANSPORTE. **BOLETIM ESTATÍSTICO - CNT - FEVEREIRO 2017.** [s.l: s.n.]. Disponível em: <<http://cms.cnt.org.br/Imagens CNT/BOLETIM ESTATÍSTICO/BOLETIM ESTATÍSTICO 2017/Boletim Estatístico - 02 - 2017.pdf>>.

CONFEDERAÇÃO NACIONAL DO TRANSPORTE; SERVIÇO SOCIAL DO TRANSPORTE; SERVIÇO NACIONAL DE APRENDIZAGEM DO TRANSPORTE. **Pesquisa CNT de rodovias 2016: Relatório gerencial.** [s.l: s.n.]. Disponível em: <[http://pesquisarodoviascms.cnt.org.br/Relatorio Geral/Pesquisa CNT \(2016\) - LOW.pdf](http://pesquisarodoviascms.cnt.org.br/Relatorio Geral/Pesquisa CNT (2016) - LOW.pdf)>.

DALAL, N.; TRIGGS, B. **Histograms of Oriented Gradients for Human Detection.** IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). **Anais...San Diego, CA, USA: IEEE**, 2005Disponível em: <<http://ieeexplore.ieee.org/document/1467360/>>

DAY, D.; WEAVER, W.; WILSING, L. Accuracy of UAS Photogrammetry: A Comparative Evaluation. **Photogrammetric Engineering & Remote Sensing**, v. 82, n. 12, p. 909–914, 1 dez. 2016.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO. **DECEA lança portal para**

orientar usuário de Drone/RPAS. Disponível em: <https://www.decea.gov.br/?i=midia-e-informacao&p=pg_noticia&materia=decea-lanca-portal-para-orientar-usuario-de-dronerpas>.

Acesso em: 17 jan. 2017.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO. **SARPAS.** Disponível em: <<http://servicos.decea.gov.br/sarpas/>>. Acesso em: 5 mar. 2017.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRASPORTE; EXECUTIVA, D.; RODOVIÁRIAS, I. DE P. **Manual de sinalização rodoviária.** 3. ed. Rio de Janeiro, Brasil: [s.n.].

DJI. **Inspire 1 - Specs, FAQ, manual, video tutorials and DJI GO.** Disponível em: <<http://www.dji.com/inspire-1/info#specs>>. Acesso em: 29 jan. 2017.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification.** 2. ed. New York: Wiley-Interscience, 2001.

FENG, W.; YUNDONG, W.; QIANG, Z. **UAV borne real-time road mapping system.** 2009 Joint Urban Remote Sensing Event. **Anais...2009**

GASZCZAK, A.; BRECKON, T. P.; HAN, J. Real-time people and vehicle detection from UAV imagery. **IS&T/SPIE Electronic Imaging**, n. 86860B, p. 1–13, San Francisco, CA, USA, Jan 2011, 2011.

GAVILÁN, M. et al. Adaptive Road Crack Detection System by Pavement Classification. **Sensors**, v. 11, n. 10, p. 9628–9657, 12 out. 2011.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens.** 3. ed. São Paulo, SP: Pearson, 2010.

GRATTAN, K. T. V.; MEGGITT, B. T. (EDS.). **Optical Fiber Sensor Technology.** Boston, MA: Springer US, 2000.

HEIPKE, C. et al. Theme issue “State-of-the-art in photogrammetry, remote sensing and spatial information science”. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 1–2, maio 2016.

ISHINO, Y.; SAJI, H. **Extraction of road markings from aerial images.** 2008 SICE Annual Conference. **Anais...IEEE**, ago. 2008 Disponível em:

<<http://ieeexplore.ieee.org/document/4655024/>>

JAHANSHAH, M. R. et al. Unsupervised Approach for Autonomous Pavement-Defect Detection and Quantification Using an Inexpensive Depth Sensor. **Journal of Computing in Civil Engineering**, v. 27, n. 6, p. 743–754, nov. 2013.

JIN, H.; FENG, Y. Automated road pavement marking detection from high resolution aerial images based on multi-resolution image analysis and anisotropic Gaussian filtering. **ICSPS 2010 - Proceedings of the 2010 2nd International Conference on Signal Processing Systems**, v. 1, p. 337–341, 2010.

KADDAH, W. et al. Road marking features extraction using the VIAPIX® system. **Optics Communications**, v. 371, p. 117–127, 2016.

KAEHLER, A.; BRADSKI, G. **Learning OpenCV 3**. 1. ed. Sebastopol: O'Reilly Media, 2016.

LIN, K.-L.; WU, T.-C.; WANG, Y.-R. An innovative road marking quality assessment mechanism using computer vision. **Advances in Mechanical Engineering**, v. 8, n. 6, p. 1–8, 2016.

MENOUAR, H. et al. UAV-Enabled Intelligent Transportation Systems for the Smart City: Applications and Challenges. **IEEE Communications Magazine**, v. 55, n. 3, p. 22–28, mar. 2017.

MOHAN, A.; POOBAL, S. Crack detection using image processing: A critical review and analysis. **Alexandria Engineering Journal**, 2017.

NIXON, M. S.; AGUADO, A. S. High-level feature extraction. In: **Feature Extraction & Image Processing for Computer Vision**. 3. ed. Oxford, UK: Elsevier, 2012. p. 217–291.

NODA, M.; KOJIMA, Y. Recognition of Road Markings from In-Vehicle Camera. **Learning**, p. 514–517, 2009.

PIX4D. **Pix4Dcapture**. Disponível em: <<https://pix4d.com/product/pix4dcapture/>>. Acesso em: 23 jun. 2017a.

PIX4D. **Pix4Dmapper Pro**. Disponível em: <<https://pix4d.com/product/pix4dmapper-pro/>>. Acesso em: 23 jun. 2017b.

PORTAL BRASIL. **Anatel exige registro para operação de drones**. Disponível em:

<<http://www.brasil.gov.br/defesa-e-seguranca/2017/01/anatel-exige-registro-para-operacao-de-drones>>. Acesso em: 17 jan. 2017.

RO, K.; OH, J.-S.; DONG, L. **Lessons Learned: Application of Small UAV for Urban Highway Traffic Monitoring**. 45th AIAA Aerospace Sciences Meeting and Exhibit. **Anais...**Reston, Virigina: American Institute of Aeronautics and Astronautics, 8 jan. 2007Disponível em: <<http://arc.aiaa.org/doi/10.2514/6.2007-596>>

RUSS, J.; NEAL, F. Acquiring Images. In: **The Image Processing Handbook**. 7. ed. Boca Raton, FL: CRC Press, 2016a. p. 1–46.

RUSS, J.; NEAL, F. Segmentation and Thresholding. In: **The Image Processing Handbook**. 7. ed. Boca Raton, FL: CRC Press, 2016b. p. 381–437.

RUSS, J.; NEAL, F. Correcting Imaging Defects. In: **The Image Processing Handbook**. 7. ed. Boca Raton, FL: CRC Press, 2016c. p. 163–242.

SCHNEBELE, E. et al. Review of remote sensing methodologies for pavement management and assessment. **European Transport Research Review**, v. 7, n. 2, 2015.

SHIH, F. Y. Pattern Recognition. In: **Image Processing and Pattern Recognition**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2010. p. 306–352.

SUGIHARTO, A.; HARJOKO, A. **Traffic sign detection based on HOG and PHOG using binary SVM and k-NN**. 2016 3rd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE). **Anais...IEEE**, 2016Disponível em: <<http://ieeexplore.ieee.org/document/7892463/>>

SUZUKI, S.; BE, K. Topological structural analysis of digitized binary images by border following. **Computer Vision, Graphics, and Image Processing**, v. 30, n. 1, p. 32–46, abr. 1985.

VEIT, T. et al. **Evaluation of Road Marking Feature Extraction**. 2008 11th International IEEE Conference on Intelligent Transportation Systems. **Anais...IEEE**, out. 2008Disponível em: <<http://ieeexplore.ieee.org/document/4732564/>>

VOKHIDOV, H. et al. Recognition of damaged arrow-road markings by visible light camera sensor based on convolutional neural network. **Sensors (Switzerland)**, v. 16, n. 12, 2016.

WANG, W. et al. A review of road extraction from remote sensing images. **Journal of Traffic and Transportation Engineering (English Edition)**, v. 3, n. 3, p. 271–282, 2016.

WEI, P. et al. A highway vehicle detection method based on the improved visual background extractor. **2015 12th International Conference on Fuzzy Systems and Knowledge Discovery, FSKD 2015**, p. 1519–1524, 2016.

WEI ZHANG et al. Moving Cast Shadows Detection Using Ratio Edge. **IEEE Transactions on Multimedia**, v. 9, n. 6, p. 1202–1214, out. 2007.

ZAKERI, H.; NEJAD, F. M.; FAHIMIFAR, A. Rahbin: A quadcopter unmanned aerial vehicle based on a systematic image processing approach toward an automated asphalt pavement inspection. **Automation in Construction**, v. 72, p. 211–235, 2016.

ZHOU, H. et al. Efficient Road Detection and Tracking for Unmanned Aerial Vehicle. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 1, p. 297–309, 2015.

ZHOU, H. et al. On Detecting Road Regions in a Single UAV Image. **IEEE Transactions on Intelligent Transportation Systems**, p. 1–10, 2016.

APÊNDICE A – CHECKLIST DE VOO

Neste apêndice é apresentado um *check-list* de voo desenvolvido para a execução de todos os voos a serem executados com o VANT. Além do *check-list*, existem os procedimentos de planejamento de voo numerados abaixo.

1. Verificar ambiente de voo (possíveis obstáculos);
2. Definir pontos de decolagem e pouso, área e altitude de voo;
3. Definir janela de operação (tempo de operação em horas);
4. Solicitar voo no SARPAS;
5. Verificar atualizações de *firmware* e aplicativo;

Cada item do planejamento é essencial para que seja adquirida, antes de qualquer voo, informações essenciais que o piloto deve ter conhecimento para executar um voo com segurança. Definidos esses procedimentos, os itens abaixo são referentes aos procedimentos no ato do voo, desde o preparo da aeronave, sua pilotagem e os procedimentos pós-voo.

1. Verificar procedimento de planejamento de-voo;
2. Verificar condições climáticas (tempo estável e vento menor que 36 km/h, use o aplicativo UAV Weather);
3. Verificar níveis de bateria dos dispositivos;
4. Retirar VANT do modo viagem;
5. Acoplar e travar câmera;
6. Acoplar e travar hélices;
7. Ligar aeronave;
8. Verificar aparatos (GPS, sensor de altitude, sinal de rádio);
9. Efetuar configurações de retorno, alarmes de bateria e limite de altitude;
10. Decolar;
11. Verificar instrumentos durante o voo, avisos e atentar ao ambiente;
12. Encontrar local propício para pouso;
13. Se for efetuar mais voos, troque a bateria e volte ao item 10; caso contrário, remover câmera e hélices;
14. Colocar VANT em modo viagem;
15. Efetuar o armazenamento de todos os aparatos.

Os itens do *check list* foram pensados de forma que qualquer procedimento de voo ocorra sem riscos a operação.

APÊNDICE B – SEGMENTAÇÃO POR CORES DE OBJETOS EM MOVIMENTO

A partir da segmentação de cores utilizando o espaço de cores HSV e lógica *fuzzy*, foi desenvolvido um trabalho que identifica e segmenta cores específicas nas patas de um cavalo. Esse trabalho desenvolvido tinha o interesse em substituir as faixas de cores específicas por cores que indicassem o esforço que o equino exercia em suas patas. Neste teste, três movimentos foram monitorados para que fosse identificado as patas, sendo estes, movimentos de trote, galope e passo. Os esforços exercidos pelo equino foram medidos através de sensores a fibra ótica encapsulados em ferraduras de fibra de carbono. Os sensores posicionados na ferradura funcionam com o princípio da deformação mecânica da fibra ótica, em que, a partir desta deformação, o comprimento de onda central do sensor alterará, permitindo medir com precisão deformações mecânicas em estruturas compostas (GRATTAN; MEGGITT, 2000). Um exemplo de imagem adquirida pode ser visualizado na Figura 34(a).

Após adquirido as imagens do cavalo em diferentes velocidades, o vídeo foi submetido a técnicas de PDI com o objetivo de identificar cada faixa. Antes de iniciar o procedimento, definiu-se uma ROI que contivesse somente a área de interesse, nesse caso, as patas do cavalo. Após, cada cor foi analisada e as seguintes condições da lógica *fuzzy* a partir das funções de pertinência da Figura 11 foram definidas: para identificar a cor branca (21), azul (22), vermelho (23) e amarelo (24). Como falhas podem ocorrer, também foi aplicado a operação morfológica de fechamento, com elemento estruturante em forma de elipse, com dimensões 6 x 2 pixels.

$$SE \ 10 \leq H \leq 80 \wedge 0 \leq S \leq 16 \wedge 96 \leq V \leq 100 \quad (21)$$

$$SE \ 210 \leq H \leq 290 \wedge 30 \leq S \leq 100 \wedge 70 \leq V \leq 100 \quad (22)$$

$$SE \ 324 \leq H \leq 360 \wedge 50 \leq S \leq 100 \wedge 81 \leq V \leq 98 \quad (23)$$

$$SE \ 30 \leq H \leq 64 \wedge 96 \leq S \leq 100 \wedge 96 \leq V \leq 100 \quad (24)$$

Detectadas as cores, estas foram substituídas por informações dos sensores conectados ao equino. Assim, definiu-se uma faixa de cores para serem apresentadas, sendo azul o menor esforço exercido e vermelho o maior. A escala de cores utilizada pode ser visualizada na Figura 34 (b) do lado esquerdo. Além disso, um zoom foi executado na ROI proporcionando melhor visualização das informações. Finalmente, um gráfico com dados dos sensores foi inserido no vídeo. O resultado final pode ser visualizado na Figura 34 (b).




Figura 34 - Identificação de cores em objetos em movimento, nesse caso, faixas coloridas presentes no cavalo. (a) Vídeo Original, (b) Vídeo Processado.

Fonte: Autoria Própria.