

Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Informática

Uma solução de baixo custo para o processamento de imagens
aéreas obtidas por Veículos Aéreos Não Tripulados

Jonas Fernandes da Silva

Dissertação submetida à Coordenação do Curso de Pós-Graduação em
Informática da Universidade Federal da Paraíba como parte dos requisi-
tos necessários para obtenção do grau de Mestre em Informática.

Área de Concentração: Ciência da Computação
Linha de Pesquisa: Sinais, Sistemas Digitais e Gráficos

Alisson Vasconcelos de Brito
(Orientador)

João Pessoa, Paraíba, Brasil

©Jonas Fernandes da Silva, 19 de fevereiro de 2016

Uma solução de baixo custo para o processamento de imagens
obtidas por Veículos Aéreos Não Tripulados

Jonas Fernandes da Silva

Dissertação aprovada no dia 19 de fevereiro de 2016

BANCA EXAMINADORA:

Alisson de Vasconcelos Brito, Dr.

Universidade Federal da Paraíba - UFPB (Orientador)

José Antônio Gomes de Lima, Dr.

Universidade Federal da Paraíba - UFPB (Coorientador)

Leonardo Vidal Batista, Dr.

Universidade Federal da Paraíba - UFPB

Joseana Macêdo Fechine Régis de Araújo, Dra.

Universidade Federal de Campina Grande - UFCG

João Pessoa, Paraíba, Brasil

Fevereiro de 2016

S586u Silva, Jonas Fernandes da.
Uma solução de baixo custo para o processamento de
imagens aéreas obtidas por veículos aéreos não tripulados /
Jonas Fernandes da Silva.- João Pessoa, 2016.
132f. : il.
Orientador: Alisson Vasconcelos de Brito
Dissertação (Mestrado) - UFPB/CI
1. Informática. 2. Monitoramento agrícola. 3. Sistemas
embarcados. 4. OpenCV. 5. 1-NN. 6. Watershed.

UFPB/BC

CDU: 004(043)

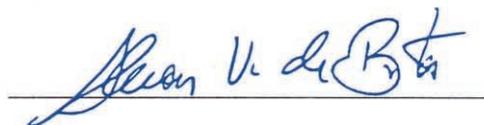
Ata da Sessão Pública de Defesa de Dissertação de Mestrado de **JONAS FERNANDES DA SILVA**, candidato ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 19 de fevereiro de 2016.

1
2 Ao décimo nono dia do mês de fevereiro do ano de dois mil e dezesseis, às quatorze horas,
3 no Centro de Informática - Universidade Federal da Paraíba (unidade Mangabeira),
4 reuniram-se os membros da Banca Examinadora constituída para julgar o Trabalho Final do
5 **Sr. Jonas Fernandes da Silva** vinculado a esta Universidade sob a matrícula 2014108707,
6 candidato ao grau de Mestre em Informática, na área de “*Sistemas de Computação*”, na
7 linha de pesquisa “*Sinais, Sistemas Digitais e Gráficos*”, do Programa de Pós-Graduação
8 em Informática, da Universidade Federal da Paraíba. A comissão examinadora foi
9 composta pelos professores: **Dr Alisson Vasconcelos de Brito (PPGI-UFPB)**, Orientador
10 e Presidente da Banca, **Dr Jose Antonio Gomes de Lima (PPGI-UFPB)**, Examinador
11 Interno, **Dr (PPGI-UFPB) Leonardo Vidal Batista (PPGI-UFPB)**, Examinador Interno, e
12 **Dra Joseana Macêdo Fechine Régis de Araújo (UFCG)**, Examinador Externo à
13 Instituição. Dando início aos trabalhos, o professor Presidente da Banca cumprimentou os
14 presentes, comunicou aos mesmos a finalidade da reunião e passou a palavra ao candidato
15 para que o mesmo fizesse, oralmente, a exposição do trabalho de dissertação intitulado
16 “*Uma solução de baixo custo para o processamento de imagens aéreas obtidas por*
17 *Veículos Aéreos Não Tripulados*”. Concluída a exposição, o candidato foi arguido pela
18 Banca Examinadora que emitiu o seguinte parecer: “*aprovado*”. Assim sendo, eu, Claurton
19 de Albuquerque Siebra, Coordenador do Programa de Pós-Graduação em Informática -
20 PPGI, lavrei a presente ata que vai assinada por mim e pelos membros da Banca
21 Examinadora.

22
23 João Pessoa, 19 de fevereiro de 2016.

24
25 
26 Claurton de Albuquerque Siebra
27

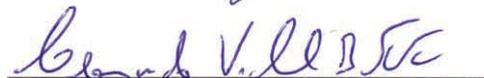
Prof Dr Alisson Vasconcelos de Brito
Orientador (PPGI-UFPB)



Prof Dr Jose Antonio Gomes de Lima
Examinador Interno (PPGI-UFPB)



Prof Dr Leonardo Vidal Batista
Examinador Interno (PPGI-UFPB)



Prof Dra Joseana Macêdo Fechine Régis de Araújo
Examinador Externo à Instituição (UFCG)



Resumo

Atualmente, veículos aéreos não tripulados (VANT) são cada vez mais utilizados no auxílio a diversas tarefas em todo o mundo. A popularização destes equipamentos associada ao avanço da tecnologia, sobretudo a miniaturização de processadores, ampliam suas funcionalidades. Em aplicações agrícolas, estes equipamentos permitem o monitoramento da produção por meio da captação de imagens aéreas, a partir dos quais são processadas e identificadas áreas de interesse por meio de *softwares* específicos. A pesquisa propõe uma solução de baixo custo capaz de processar imagens aéreas obtidas por câmeras digitais não métricas acopladas a VANT para identificar falhas em plantações ou estimar níveis de degradação ambiental, os quais possam ser implantados em computadores de pequeno porte e baixo consumo, conhecido como sistemas embarcados. Plataformas embarcadas acopladas a VANT permitem realizar o processamento em tempo real, que contribui para um diagnóstico preventivo, reduz o tempo de resposta e pode evitar prejuízos na lavoura. O algoritmo inicialmente avaliado é baseado em *watershed*, enquanto que o segundo algoritmo proposto faz uso de técnicas de classificação baseada no 1-vizinho mais próximo (1-NN). Utilizam-se os sistemas embarcados *DE2i-150* e *Intel Edison*, ambos de arquitetura x86, e a plataforma *Raspberry Pi 2* de arquitetura ARM. Em relação ao processamento das imagens são alcançados níveis de acurácia em torno de 90%, com uso do algoritmo baseado em 1-NN. Além disso, a técnica 1-NN apresentou maior tolerância aos problemas de luminosidade, em contrapartida, demandam maior poder de processamento quando comparados com o algoritmo baseado em *watershed*. Os resultados mostram que o sistema proposto é uma solução eficiente e de custo relativamente baixo em comparação com os meios tradicionais de monitoramento e pode ser acoplada em um VANT para realizar o processamento durante o voo.

Palavras-Chave: Monitoramento agrícola, Sistemas embarcados, *OpenCV*, 1-NN, *Watershed*.

Abstract

Currently, unmanned aerial vehicles (UAV) are increasingly used to aid the various tasks around the world. The popularization of this equipment associated with the advancement of technology, particularly the miniaturization of processors, extend their functionalities. In agricultural applications, these devices allow monitoring of production by capturing aerial images, for which are processed and identified areas of interest through specific software. The research proposes a low-cost solution capable of processing aerial images obtained by non-metric digital cameras coupled to UAV to identify gaps in plantations or estimate levels of environmental degradation, which can be deployed in small computers and low power consumption. Embedded systems coupled in UAV allow perform processing in real time, which contributes to a preventive diagnosis, reduces the response time and can avoid damages in the crop. The algorithm used is based on watershed, while the second algorithm uses classification techniques based on the 1-Nearest Neighbor (1-NN). Are used the embedded systems *DE2i-150* and *Intel Edison*, both x86 architecture, and *Raspberry Pi 2* of ARM architecture. Moreover, the technique 1-NN showed higher tolerance to lighting problems, however, require more processing power compared to the algorithm based on watershed. The results show that the proposed system is an efficient and relatively low-cost solution compared to traditional means of monitoring and can be coupled in a UAV to perform the processing during the flight.

Keywords: Agricultural Monitoring, Embedded systems, OpenCV, Watershed.

Dedicatória

*Aos meus tios Orlando Fernandes (in memorian) e Severino Fernandes (in memorian),
que proporcionaram grandes momentos de alegria em família,
sobretudo nesta etapa importante da minha vida.
Dedico.*

*Especialmente à minha mãe, esposa e filha,
que tiveram grande influência para
este trabalho se tornar realidade.
Dedico.*

Agradecimentos

Agradeço a Deus, que me fortalece a cada dia, pela saúde e pelo trabalho. Sem Ele não teria sabedoria para escolher os caminhos certos para conquistar meus objetivos.

Agradeço ao meu orientador, prof. Dr. Alisson Vasconcelos, pela apresentação de um problema interessante e pelas valiosas sugestões durante todas as etapas do mestrado.

Ao meu co-orientador prof. Dr. José Antônio Gomes de Lima que acolheu, sem medir esforços, as ideias iniciais deste projeto e as encaminharam ao destino certo.

A todos os professores do PPGI que contribuíram para a realização deste trabalho, em especial à profa. Thaís Gaudêncio, pelas valiosas sugestões desde a construção dos primeiros artigos e ao prof. Leonardo Vidal pelas correções e sugestões propostas.

À Profa. Dra. Nadjacleia Vilar Almeida, pela realização dos trabalhos de campo e apresentação de problemas ambientais. Aos pesquisadores da área ambiental Hugo Yuri, pelos sobrevoos realizados na área de preservação e aos professores Lincoln Eloi e Milena Dutra, pelas análises de resultados deste trabalho.

Ao amigo Helder Nogueira e aos colegas do PPGI Matheus Cordeiro, José Cláudio e Thiago Werlley, pela parceria e troca de experiências durante a parte prática deste projeto.

Agradeço aos meus pais, especialmente à minha mãe, Maria de Fátima Fernandes, que durante toda a minha vida acadêmica me apoiou, passou tranquilidade e confiança para que eu pudesse atingir meus objetivos.

Agradeço especialmente à minha amada esposa, Tacianne de Oliveira, pela generosa paciência, compreensão e por todo o incentivo para seguir em frente quando encontrei dificuldades. E também por cuidar com muita dedicação e carinho da nossa filha Júlia, que através da simplicidade de seu sorriso ajudou a renovar as esperanças em vários momentos difíceis presentes nesta jornada.

Agradeço às minhas irmãs Jacilene, Janaína e Jane, que sempre torceram para que essa etapa se concretizasse em minha vida. Aos meus sobrinhos Neto, Joyce, Joanne e Juliana que em algumas tardes proporcionaram bons momentos de descontração.

Agradeço a todos que, direta ou indiretamente, contribuíram para esta nova conquista em minha vida.

Conteúdo

1	Introdução	1
1.1	Descrição do Problema	3
1.2	Motivação	5
1.3	Objetivos	6
1.3.1	Objetivos Específicos	6
1.4	Metodologia	7
1.5	Estrutura da Dissertação	8
2	Processamento Digital de Imagens	10
2.1	Obtenção de Imagens aéreas com uso de VANT	10
2.2	Formação de Imagens Digitais	14
2.3	Processamento de Imagens	16
2.3.1	Pré-processamento	18
2.3.2	Segmentação de imagens por limiarização	18
2.3.3	Segmentação baseada em <i>Watershed</i>	20
2.4	Processamentos de Imagens coloridas no contexto agrícola	23
2.4.1	Espaço de cores RGB e HSI	23
2.4.2	Técnicas de Aprendizagem de Máquina	27
2.4.3	Classificação baseada na regra do 1-vizinho mais próximo	27
3	Sistemas Embarcados	30
3.1	Conceitos e visão geral	30
3.1.1	Sistemas em tempo real	34
3.2	Sistemas embarcados em VANT	35

3.3	Características dos processadores	37
3.3.1	Arquiteturas CISC e RISC	38
3.4	Software em sistemas embarcados	40
3.5	Características dos sistemas embarcados	41
4	Pesquisas Correlatas	49
5	Materiais e Métodos	56
5.1	Obtenção de imagens e Processamento	57
5.2	Processamento baseado em Watershed	59
5.3	Processamento baseado na técnica do 1 - Vizinho mais próximo	62
5.3.1	Inferência estatística aplicada ao conjunto de dados	65
5.3.2	Avaliação do modelo de dados	72
5.4	Aplicações Ambientais	74
5.5	Avaliações de desempenho	76
5.5.1	Avaliação em termos de acurácia	77
5.5.2	Desempenho em relação ao tempo de execução	78
6	Resultados e Discussão	80
6.1	Avaliação da segmentação	80
6.1.1	Variação de dados de treinamento para a técnica 1-NN	81
6.1.2	Comparação de resultados	85
6.2	Tempo de processamento	95
6.3	Eficiência energética	98
6.4	Publicações aceitas e submetidas	104
7	Considerações Finais	105
7.1	Principais contribuições	107
7.2	Sugestões para Trabalhos Futuros	107
	Referências Bibliográficas	115

Lista de Siglas e Abreviaturas

1-NN : *1-nearest neighbor*

AM : Aprendizagem de Máquina

APA : Área de Proteção Ambiental

AT : *Advanced Technology*

CISC : *Complex Instruction Set Computer*

CPU : *Central Processing Unit*

DC : *Direct Current*

DDR : *Double Data Rate*

DSP : *Digital Signal Processor*

E/S : Entrada/Saída

ELM : *Extreme Learning Machine*

EMBRAPA : Empresa Brasileira de Pesquisa Agropecuária

FPGA : *Field Programmable Gate Array*

GPIO : *General Purpose Input/Output*

GPS : *Global Positioning System*

GPU : *Graphics Processing Unit*

HDMI : *High-Definition Multimedia Interface*

HSI : *Hue, Saturation, Intensity*

IA : *Inteligência Artificial*

IEEE : *Institute of Electrical and Electronics Engineers*

INPA : *Instituto Nacional de Pesquisas da Amazônia*

ISO : *International Organization for Standardization*

k-NN : *k-nearest neighbor*

LTS : *Long Term Support*

LPDDR : *Low Power DDR*

MSE : *Mean square error*

NASA : *National Aeronautics and Space Administration*

NDVI : *Normalized Difference Vegetation Index*

NIR : *Near Infrared*

NRE : *Non-Recurring Engineering*

OTG : *On-The-Go*

PSNR : *Peak signal-to-noise ratio*

REM : *Radiação Eletromagnética*

RGB : *Red, Green, Blue*

RISC : *Reduced Instruction Set Computer*

RNA : *Rede Neural Artificial*

SD : *Secure Digital*

SIFT : *Scale-Invariant Feature Transform*

SIG : *Sistema de Informação Geográfica*

SNR : *Signal-to-noise ratio*

SoC : *System On Chip*

SOM : *Self Organizing Map*

SSD : *Solid-State Disk*

SSH : *Secure Shell*

SWIR : *Short Wave Infrared*

USB : *Universal Serial Bus*

VANT : *Veículo Aéreo Não-Tripulado*

VGA : *Video Graphics Array*

Lista de Figuras

2.1	VANT <i>Pathfinder Plus</i> em sobrevoo no Hawaii, EUA.	12
2.2	Modelos de VANT de pequeno porte	14
2.3	Representação de uma imagem digital em nível de pixel	17
2.4	Processo de limiarização em imagem com valor $T = 200$	20
2.5	Ilustração do processo de imersão da transformada <i>watershed</i>	21
2.6	Resultado da etapa de dilatação de imagem	22
2.7	Representação do espaço de cores RGB	24
2.8	Representação do espaço de cores HSI	25
2.9	Processo de aprendizagem baseado em instâncias	29
3.1	Estrutura básica de um computador	31
3.2	Diagrama em blocos de um computador convencional	32
3.3	Diagrama em blocos de um sistema embarcado	33
3.4	Camadas de <i>software</i> entre computadores	40
3.5	Plataforma embarcada <i>DE2i-150</i>	42
3.6	Diagrama em blocos da plataforma <i>DE2i-150</i>	43
3.7	Plataforma <i>Intel Edison</i>	44
3.8	Diagrama em blocos da plataforma <i>Intel Edison</i>	45
3.9	Plataforma <i>Raspberry P 2</i>	46
4.1	Resultado do processamento baseado em RNA	51
5.1	Modelo de VANT FC-40 utilizado na captura de imagens ambientais	58
5.2	Imagens após etapas iniciais do algoritmo <i>Watershed</i>	60
5.3	Comparação entre imagem em escala de cinza e primeira etapa de limiarização	60

5.4	Comparação entre imagem após a etapa de dilatação	61
5.5	Resultados após a etapa de transformada de distância e segunda limiarização	62
5.6	Diagrama em blocos da obtenção de dados de treinamento e avaliação do modelo	66
5.7	Histograma com níveis de cinza do canal R com 427 amostras	68
5.8	Histograma com níveis de cinza do canal G com 427 amostras	69
5.9	Histograma com níveis de cinza do canal B com 427 amostras	69
5.10	Histograma com níveis de cinza do canal R com 128 amostras	70
5.11	Histograma com níveis de cinza do canal G com 128 amostras	71
5.12	Histograma com níveis de cinza do canal B com 128 amostras	72
5.13	Imagem segmentada (a) e representação de áreas encontradas (b)	75
5.14	Exemplo de imagens enviadas aos especialistas para avaliação dos métodos	78
6.1	Histograma de frequência da limiarização T_1	85
6.2	Histograma de frequência da limiarização T_2	86
6.3	Tempo para o processamento de imagens utilizando a técnica baseada em <i>watershed</i> em diferentes plataformas	96
6.4	Tempo para o processamento de imagens utilizando a técnica baseada em 1-NN em diferentes plataformas	97
6.5	Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo <i>watershed</i> na plataforma <i>DE2i-150</i>	99
6.6	Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo 1-NN na plataforma <i>DE2i-150</i>	99
6.7	Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo <i>watershed</i> na plataforma <i>Raspberry Pi 2</i>	100
6.8	Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo 1-NN na plataforma <i>Raspberry Pi 2</i>	101
6.9	Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo <i>watershed</i> na plataforma <i>Intel Edison</i>	102
6.10	Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo 1-NN na plataforma <i>Intel Edison</i>	102

Lista de Tabelas

2.1	Fonte de origem de imagens e principais áreas de aplicação	15
3.1	Principais plataformas embarcadas disponíveis no mercado	47
3.2	Comparação entre os sistemas embarcados utilizados	48
4.1	Quadro comparativo com os principais trabalhos relacionados	55
5.1	Estatísticas sobre os canais RGB com 427 amostras de treinamento	67
5.2	Estatísticas sobre os canais RGB com 128 amostras de treinamento	70
5.3	Matriz de confusão para o problema com duas classes	73
5.4	Coordenadas centrais $P(x,y)$ estimadas para áreas de falhas	76
6.1	Matriz de confusão do algoritmo 1-NN com 427 instâncias com parâmetro N=10	81
6.2	Matriz de confusão do algoritmo 1-NN com 128 instâncias com parâmetro N=10	81
6.3	RMSE entre imagens processadas com 427 e 128 amostras	82
6.4	Resultados do processamento através da técnica do 1-vizinho mais próximo com 427 e 128 amostras de treinamento para imagens da APA	83
6.5	Resultados do processamento através da técnica do 1-vizinho mais próximo com 427 e 128 amostras de treinamento para imagens da região agrícola de cana de açúcar	84
6.6	Imagens originais e segmentadas através das técnicas baseadas em <i>watershed</i> e 1-NN com 128 instâncias de treinamento para região agrícola	86

6.7	Escolha do especialista para representação do melhor método de segmentação a partir de experimentos com 20 imagens da região de cana-de-açúcar	89
6.8	Imagens originais e segmentadas através das técnicas baseadas em <i>watershed</i> e 1-NN com 128 instâncias de treinamento para região ambiental	90
6.9	Escolha do especialista para representação do melhor método de segmentação a partir de experimentos com 20 imagens da região ambiental	93
6.10	Percentual de solo exposto em imagens ambientais	94
6.11	Tempo de processamento com uso do algoritmo baseado em 1-NN	95
6.12	Tempo de execução do algoritmo baseado em <i>watershed</i>	95
6.13	Tempo de execução do algoritmo baseado em 1-NN	97
6.14	Consumo de energia (<i>em watts</i>) nos sistemas embarcados	103
6.15	Análise comparativa dos algoritmos avaliados	103

Lista de Códigos Fonte

5.1	Trecho para conversão da imagem em escala de cinza	59
5.2	Trecho do código de conversão do espaço de cores RGB para HSI	63
5.3	Código <i>Shell script</i> para cálculo do tempo de processamento	79

Capítulo 1

Introdução

A escassez dos recursos naturais devido ao crescimento da população global provoca alguns tipos de exploração de recursos em regiões anteriormente inacessíveis (ANTONIO et al., 2012) para fornecer alimentos e outros produtos à base de biomassa (BARRETTO et al., 2013). No Brasil, apenas uma pequena parte dos recursos naturais se refere às áreas cultiváveis, possuindo limitada disponibilidade de espaço para novos cultivos. Segundo (ZARBIN; RODRIGUES, 2009), o setor agrícola no Brasil passa por uma reformulação devido ao crescimento populacional e a limitada expansão da área territorial agrícola, onde o foco atual é o controle de pragas e doenças, impulsionando as inovações tecnológicas nos fatores de produção, de modo que o aumento de produção ocorra somente pelo aumento de produtividade em um mesmo espaço territorial. Abordagens que envolvem inovações tecnológicas no setor agrícola visam aumentar cada vez mais a eficiência da agricultura, melhorar a rentabilidade e reduzir impactos ambientais (HERWITZ et al., 2004), como, por exemplo, o uso de veículos aéreos não tripulados para o monitoramento de lavouras.

Segundo a *International Civil Aviation Organization* (ICAO), um veículo aéreo não tripulado (VANT) é uma aeronave que voa sem piloto em comando a bordo, e é também remota e completamente controlada de outro lugar (solo, outra aeronave, do espaço) ou programada com total autonomia (ICAO, 2005). Inicialmente, os VANT foram desenvolvidos apenas para uso militar. Experimentos com aviões não tripulados começaram no final da primeira guerra mundial (BLOM, 2010) e até hoje são considerados como parte integrante e indispensável das forças armadas modernas, cuja evolução ao longo do tempo permitiu um número crescente de utilização em aplicações civis (GONZÁLEZ-ESPASANDÍN; LEO; NAVARRO-

ARÉVALO, 2014). Projetados para as mais variadas necessidades, desde os maiores e potentes, até os menores e mais ágeis, são capazes de assumir funções versáteis, principalmente em ambientes que oferecem riscos à vida ou onde a intervenção humana é difícil ou perigosa. Podem ser remotamente controlados, por meio de comunicações por satélite com uso de GPS ou enlace de dados, ou ainda podem ser capazes de realizar voos autonomamente (PING et al., 2012)(LIU; DAI, 2010). Em consequência da recente crise internacional, houve redução de investimentos em projetos aplicados à defesa nacional de países líderes como Alemanha, França e Estados Unidos, resultando em um impacto negativo sobre o crescimento da indústria de VANT para aplicações militares. Em contrapartida, um crescimento do número de empresas de pequeno e médio porte é observado em todo mundo voltado à fabricação destes equipamentos para aplicações específicas (DRUBIN, 2015), o que representa um mercado promissor e em pleno desenvolvimento.

O crescimento da indústria de eletrônica nos últimos anos tem contribuído para os avanços na área de tecnologia computacional, que associado à crescente demanda por novas funções em equipamentos do cotidiano resultam em um amplo espaço aos sistemas embarcados. Segundo (TAURION, 2005), aproximadamente 98% dos processadores do mundo estão operando em sistemas embarcados, por meio de dispositivos especializados, com uso de microprocessadores, microcontroladores ou processadores de sistemas digitais (do inglês *Digital Signal Processor - DSP*) encontrados praticamente em todos os lugares e objetos que disponham de eletricidade, sejam por rede elétrica ou baterias. Estes dispositivos oferecem diversas vantagens e contribuem para o desenvolvimento de novos produtos e aplicações em diversas áreas do conhecimento, inclusive no campo da visão computacional.

Em grandes áreas de plantações, VANT otimizam a produção pelos agricultores, auxiliando a tarefa do monitoramento agrícola por meio da captura de imagens aéreas. O seu uso é cada vez mais frequente devido à economia gerada por estes equipamentos, que eliminam gastos com deslocamento terrestre de especialistas e reduzem o tempo de resposta para a identificação do problema, tornando mais eficiente a tomada de decisão e melhorando a precisão no gerenciamento de lavouras. Segundo Moreira (MOREIRA, 2003), as fotografias aéreas na agricultura podem ser utilizadas no mapeamento de culturas, avaliação de áreas cultivadas, detecção de áreas afetadas, cadastros rurais e no mapeamento do solo. A principal vantagem do uso de VANT para a captação de imagens aéreas é a capacidade de percorrer

uma distância considerável com segurança, tempo reduzido e menor custo, comparado, por exemplo, com o uso de uma aeronave tripulada.

1.1 Descrição do Problema

Em uma extensa região agrícola ou ambiental, a atividade de monitoramento é uma tarefa complexa e custosa. Em muitos casos exige o deslocamento de especialistas até o local de interesse para a identificação do problema, culminando em um maior tempo de espera para a tomada de decisões, causando prejuízos.

Imagens de satélite para a realização de monitoramento e mapeamentos de áreas de interesse são amplamente utilizadas, porém, algumas dificuldades são relatadas e outros pontos negativos são observados, como, por exemplo, a característica de baixa resolução de imagens impossibilita a identificação de áreas pequenas de plantio no monitoramento de cana-de-açúcar descrito em (MENDONÇA et al., 2011), dificultando o correto mapeamento nessas áreas. Em (FRANCO; LIRA, 2007) houve a necessidade de visitas a campo para o registro por meio de fotos manuais para avaliação de possíveis mudanças na cobertura vegetal e identificar áreas de degradação. Assim também como ocorre em (NASCIMENTO et al., 2006), (ASSIS; ALMEIDA; SANTOS, 2014), em que o mapeamento a partir de imagens de satélite necessitou da etapa de validação por vias terrestres para a identificação das classes de uso da terra e cobertura vegetal. Tal tarefa demandou grande esforço de caminhada nos levantamentos de campo para contornar possíveis erros no processo de classificação, provenientes de fatores como a baixa resolução das imagens obtidas por satélite ou impossibilidade de visualização da área de interesse devido à presença de nuvens na imagem.

A técnica de fotogrametria, de maneira geral, consiste na ciência e tecnologia de se obter informação confiável através de imagens adquiridas por sensores (BRITO; COELHO, 2002), sendo a fotogrametria aérea muito eficiente para mapeamento de grandes áreas. Normalmente ainda utilizam câmeras métricas para a aquisição de imagens aéreas a partir de um avião tripulado, de modo que sejam posteriormente processadas para a finalidade desejada. Câmeras métricas são desenvolvidas com lentes especiais para garantir alto nível de estabilidade geométrica e qualidade de projeção (JUNIOR et al., 2009) (CÔRTEZ, 2010), ideais para uso em fotogrametria, pois evitam distorções e garantem conformidade na projeção.

Porém, câmeras métricas apresentam alto custo de aquisição. Ao contrário, as câmeras não-métricas, comumente utilizadas nos dias de hoje, não garantem estabilidade geométrica, mas o seu baixo custo de aquisição torna-as acessíveis para diversas tarefas e apresentam potencial uso em fotogrametria (Jr. Santos; MITISHITA; MACHADO, 2004), tendo em vista que as instabilidades de alguns parâmetros não afetam significativamente o resultado da imagem e por isso são utilizadas para esta e outras finalidades, desde que sejam adotadas técnicas de calibração como as apresentadas em (Jr. Santos; MITISHITA; MACHADO, 2004)(HABIB et al., 2008)(CLARKE; FRYER, 1998) amenizando as distorções encontradas. O uso convencional da fotogrametria para tarefas em médias e pequenas áreas é economicamente custosa, pois envolvem altos gastos com a necessidade de aeronaves tripuladas, oferecem maiores riscos e requerem um grande planejamento para realizar cada sobrevoo.

Os avanços do campo da visão computacional fomentam diversos estudos com uso de VANT para a realização de múltiplas tarefas, inclusive a aplicação de técnicas de fotogrametria, conforme os estudos (JÚNIOR; CÔRTEZ; FERREIRA, 2014) e (JÚNIOR et al., 2015), nos quais foi validada a utilização de câmera não-métrica acoplada a estes equipamentos para a geração de mosaicos e ortomosaicos. Outros estudos relacionados à fotogrametria são relatados em (MITISHITA et al., 2014), (COLOMINA; MOLINA, 2014) e (OLIVEIRA et al., 2014). Devido à alta flexibilidade de uso de VANT, várias outras áreas são beneficiadas com o uso destes equipamentos, como, por exemplo, o uso em arqueologia (SALERI et al., 2013), em que um VANT auxilia no mapeamento para modelagem de imagens 3D de um desenho urbano. Aplicações em segurança também são objetos de estudo conforme os trabalhos (FELIZARDO et al., 2013) e (MOTA et al., 2013), em que um VANT é utilizado para vigilância em áreas urbanas visando à detecção de alterações não autorizadas na terra, como por exemplo, desmatamento para construções de casas ou estradas. Um sistema de detecção e contagem de copa das árvores da espécie palmeira é proposto em (MALEK et al., 2014). Em (UTO et al., 2013) é descrito o uso de VANT com sensor hiperespectral acoplado para a caracterização de plantações de arroz no Japão. Aplicados à gestão do cultivo, podem auxiliar na classificação de culturas e realização de tarefas que envolvem mapeamento (BERNI et al., 2009).

Apresentadas algumas características das principais formas de mapeamento e monitoramento do uso da terra, apontam-se os principais problemas e limitações de cada uma das

técnicas envolvidas:

- Imagens de satélite possuem baixa resolução e um alto custo de aquisição, além de baixa taxa de atualização inviabilizando o seu uso em situações que requerem atualização em curto intervalo de tempo e são dependentes do clima, não sendo possível a aquisição de boas imagens da superfície em dias nublados. Muitas vezes necessitam da perspectiva humana para complementação da informação obtida, tendo em vista obstáculos encontrados na imagem, ficando suscetíveis a informações incompletas e demandando alto consumo de tempo.
- Alternativas como a fotogrametria aérea envolve elevados custos e difícil logística, devido à necessidade de utilizar aviões tripulados e requerem planejamento prévio para autorização de voos, demandando maior tempo para o monitoramento e consequentemente a tomada de decisão.
- O uso de VANT é uma boa opção para o imageamento aéreo, apresentam alta resolução, comparado a imagens de satélites, baixo custo e são de fácil operação. Porém, na maioria dos casos, o processamento das imagens ocorre posteriormente (FELIZARDO et al., 2013) em uma estação terrestre ou em laboratório, e em outros, as imagens são disponibilizadas pelo VANT somente depois de algumas horas (AHMAD et al., 2013), retardando o tempo de reposta na tomada de decisão sobre a solução do problema identificado.

1.2 Motivação

Veículos Aéreos Não Tripulados são amplamente utilizados no setor agrícola, especialmente no auxílio a tarefas de monitoramento. Estes equipamentos podem identificar áreas de solo em exposição presente em lavouras, que sinalizam a presença de pragas, problemas no solo ou na irrigação. Ampliando o contexto agrícola, podem fornecer informações sobre delimitação de áreas de vegetação e auxiliar a análise do uso e cobertura da terra provendo, inclusive, estimativas de áreas danificadas e muitas outras funcionalidades. Outras aplicações ambientais também podem ser desenvolvidas com o uso de VANT, como a contagem de espécies de plantas e a identificação de queimadas em florestas. Em tais aplicações, o processamento

em tempo real contribui significativamente para a redução do tempo de resposta para solução do problema. Essa característica é fundamental principalmente nas ocasiões que oferecem perigo à vida e ao meio ambiente, de modo a evitar prejuízos, auxiliar na produção ou evitar desastres de grandes proporções.

A configuração para a realização de tarefas específicas agrega novas funcionalidades aos VANT, de forma a realizar tarefas automaticamente que antes demandavam maior tempo de execução, esforço humano e alto custo operacional. Para tal, o uso de sistemas flexíveis é necessário para adaptabilidade às mais variadas tarefas. A evolução dos sistemas embarcados, que a cada dia tem seu tamanho reduzido e sua capacidade de processamento ampliada, contribui para expansão de capacidades em diversos equipamentos e permite a realização de novas tarefas.

Como existe uma grande variedade de sistemas embarcados no mercado, é necessário investigar a solução que melhor atenda os requisitos básicos para utilização em VANTs e desenvolver um sistema capaz de realizar o processamento de imagens durante o voo, possibilitando uma análise prévia pelo próprio VANT, dispensando a necessidade de pousar para descarregar imagens. Os principais requisitos do sistema para acoplamento ao VANT se referem à taxa de acerto (acurácia), desempenho, consumo de energia e peso, pois estão associadas ao algoritmo utilizado e à autonomia do VANT. Nesse contexto, este trabalho aborda características dos sistemas embarcados avaliados e faz uma comparação de resultados em relação aos requisitos do sistema.

1.3 Objetivos

O objetivo geral desta dissertação é apresentar uma proposta de sistema de processamento de imagens aéreas de baixo custo que possa ser embarcada em computadores de porte leve e de baixo consumo de energia aplicados ao monitoramento de áreas agrícolas ou regiões ambientais em tempo real.

1.3.1 Objetivos Específicos

- Propor e avaliar a melhor técnica utilizada para segmentação de imagens obtidas por câmeras não-métricas;

- Buscar a plataforma computacional mais adequada para ser acoplada a um VANT de pequeno porte.

1.4 Metodologia

Para alcançar os objetivos desta dissertação, alguns passos foram adotados. Inicialmente, um levantamento bibliográfico acerca das técnicas utilizadas para o monitoramento de grandes áreas de plantações é realizado. A seguir, é construída a fundamentação teórica iniciando por uma base sobre formação e características de imagens digitais, essencial para entender as etapas de processamento. Técnicas de aprendizagem de máquina são estudadas para aplicá-las ao processamento de imagens possibilitando que o algoritmo proposto funcione de forma mais eficiente e com a menor interferência humana possível.

O segundo passo é conhecer características dos sistemas embarcados baseados nas arquiteturas x86 e ARM, assim como especificidades dos tipos de processadores, de modo que o sistema proposto atenda os requisitos básicos para a sua implantação. A sintonia entre o conhecimento das técnicas e algoritmos utilizados para o processamento de imagens garantirá o bom desempenho do sistema implantado nas plataformas embarcadas.

O terceiro passo deste trabalho tem por objetivo implantar os algoritmos de processamento de imagens baseados nas técnicas *watershed* e 1-vizinho mais próximo, cuja função principal é a segmentação de imagens aéreas visando à detecção de solo exposto em regiões agrícolas ou ambientais. Os algoritmos são implantados a partir da biblioteca de *software* de visão computacional *OpenCV*. Nesta etapa, vários testes são realizados com imagens de uma região agrícola de cana-de-açúcar e uma região de área de preservação ambiental. Apesar de algumas imagens serem adquiridas por meio de trabalho de campo com uso de VANT, todas as etapas de processamento foram realizadas em laboratório. Os resultados foram avaliados por especialistas do setor agrícola e ambiental.

Após a análise da viabilidade dos algoritmos, a próxima etapa busca implantá-los em computadores de porte leve e baixo consumo de energia em arquiteturas x86 e ARM. Para tal, são escolhidos os sistemas embarcados *DE2i-150*, *Intel Edison* e *Raspberry Pi 2* para avaliação de resultados em relação às principais métricas conhecidas. As métricas de desempenho são comparadas entre os sistemas embarcados e um computador pessoal. Enquanto

que métricas relacionadas ao consumo de energia e peso são avaliadas somente entre os sistemas embarcados.

A partir dos resultados da avaliação do algoritmo e plataformas utilizadas, discutem-se os resultados que melhor se adequam às necessidades para que o processamento de imagens seja realizado em tempo real durante o voo.

Diante do exposto acima, é possível sintetizar as principais etapas metodológicas para a construção deste trabalho:

- Desenvolver um algoritmo para o processamento de imagens capaz de identificar áreas de solo exposto em uma imagem de região agrícola ou ambiental;
- Avaliar o comportamento do algoritmo inserido nos sistemas embarcados em relação ao tempo de processamento e eficiência energética;
- Avaliar as possibilidades de melhoria no sistema em relação à segmentação de imagens e tempo de processamento;
- Validar o sistema proposto, em laboratório, a partir de experimentos com vários grupos de imagens aéreas de regiões agrícolas e áreas de preservação ambiental, verificando sua viabilidade a partir de análises de especialistas.

1.5 Estrutura da Dissertação

Esta dissertação é composta por sete capítulos. O Capítulo 2 traz conceitos sobre a formação de imagem digital e trata de técnicas de processamento de imagens baseado em *watershed* e na técnica baseada em aprendizagem de máquina (AM) por meio da classificação baseada no 1-vizinho mais próximo (1-NN). O Capítulo 3 aborda os sistemas embarcados, com ênfase nas arquiteturas x86 e ARM, sendo apresentados alguns conceitos importantes e as principais métricas de projeto. O Capítulo 4 apresenta alguns trabalhos relacionados. O Capítulo 5 aborda o desenvolvimento do sistema, trazendo detalhes sobre as etapas de obtenção e processamento de imagens e sua implementação nos sistemas embarcados, além das técnicas empregadas para avaliação dos métodos. O Capítulo 6 apresenta os resultados alcançados após a etapa de segmentação, a partir das duas técnicas empregada, bem como após a implan-

tação em computadores de pequeno porte. O Capítulo 7 apresenta as considerações finais e sugere trabalhos futuros, além de destacar as principais contribuições da pesquisa.

Capítulo 2

Processamento Digital de Imagens

Este capítulo apresenta uma visão geral sobre conceitos de imagem digital e técnicas de processamento. A Seção 2.1 apresenta algumas técnicas de obtenção de imagens aéreas utilizadas em aplicações ambientais e agrícolas. A Seção 2.2 aborda conceitos sobre a formação de imagens digitais. A Seção 2.3 trata das etapas de processamento a partir de imagens em tons de cinza. Para isso, a etapa de pré-processamento utilizada é mostrada na Subseção 2.3.1, seguido da apresentação das etapas de limiarização (Subseção 2.3.2) e técnica baseada em *watershed* (Subseção 2.3.3).

A Seção 2.4 descreve a segmentação de imagens com uso dos três canais RGB a partir de uma técnica baseada em aprendizagem de máquina (AM) que consiste na classificação baseada no 1-vizinho mais próximo (1-NN). Inicialmente, é mostrada na Subseção 2.4.1 uma etapa de conversão do espaço de cores RGB para HSI. A Subseção 2.4.2 apresenta alguns conceitos de AM e finalmente na Subseção 2.4.3 é apresentada a técnicas de aprendizagem baseada em 1-vizinho mais próximo.

2.1 Obtenção de Imagens aéreas com uso de VANT

Em abordagens tradicionais sobre as técnicas de monitoramento ambiental, o uso de VANT por muitas vezes se torna restrito à captação das imagens, que normalmente são submetidas a computadores e *softwares* específicos para realizar o processamento destas imagens posteriormente.

Em aplicações ambientais, vários registros com uso de VANT são encontrados, especi-

almente na agricultura de precisão, cujas imagens podem ser obtidas para o monitoramento de lavouras, estimativas de volume de produção e índice de doenças e pragas (MEDEIROS, 2007). O trabalho descrito em (JORGE; BRANDÃO; INAMASU, 2014) apresenta um VANT com sensores hiperspectrais acoplados para detectar a infestação de *Huanglongbing* (HLB), uma doença destrutiva encontrada na agricultura de citros no Brasil, e mostrou que é possível a detecção com alta precisão de doenças em culturas através de imagens obtidas por VANT. Em (URBAHS; JONAITE, 2013) é citada a construção de um VANT com sensores especiais para obtenção de ortophotos de alta resolução e fotografias multiespectrais, que permitem a identificação de presença de doenças e dos efeitos adversos de inseticidas utilizados na plantação. Segundo o autor, é necessário considerar alguns pontos importantes para tomar a decisão correta na escolha ou construção de VANT independentemente da aplicação, uma delas é assegurar a decolagem e aterrissagem bem sucedidas mesmo quando não houver pista de decolagem.

Em (HERWITZ et al., 2004) é apresentado um VANT movido a energia solar com capacidade de coletar imagens por várias horas com o objetivo de monitorar uma plantação em busca de identificar focos de ervas daninhas invasoras, bem como encontrar anormalidades na irrigação ou fertilização. A missão consistia em sobrevoar o espaço aéreo dos Estados Unidos com equipamentos para monitorar, por um prolongado período de tempo, uma região agrícola do cultivo de café localizada no Hawaii utilizando o modelo de VANT *Pathfinder Plus* desenvolvido pela *National Aeronautics and Space Administration* (NASA). O modelo é equipado com oito motores elétricos alimentados por energia solar, possui 36,3 metros de envergadura e 318Kg de peso bruto. Foram utilizados dois sistemas complementares de câmeras com operação remota, respeitando as limitações de 68 Kg de carga e 500 W de energia gerado pelos painéis solares. O primeiro captura as imagens em alta resolução para interpretação qualitativa e mapeamento, enquanto que o segundo captura imagens multiespectrais para análise quantitativa da colheita em relação à maturação. Os autores concluíram que VANT complementam a utilização de satélites que permanecem limitados na capacidade de fornecer imagens de resolução adequadas para muitos aspectos na agricultura comercial. A Figura 2.1 mostra o modelo de VANT *Pathfinder Plus* em sobrevoo.

Em (KONTITSIS; VALAVANIS; TSOURVELOUDIS, 2004), é apresentado um sistema de visão computacional capaz de interpretar e processar dados adquiridos por um VANT

Figura 2.1: VANT *Pathfinder Plus* em sobrevoo no Hawaii, EUA.

Fonte: NASA (CONNER; DUNBAR, 2002)

através de câmeras infravermelhas acopladas para a detecção de incêndios em florestas. Os componentes do sistema incluem redução de ruído, extração de características, classificação e tomada de decisão. Este último componente aciona um alarme em caso de detecção de fogo.

A utilização de câmeras não-métricas de baixo custo são comumente utilizadas e também podem ser acopladas a VANT para o imageamento aéreo em várias aplicações. Em (FELIZARDO et al., 2013) é apresentado um sistema capaz de coletar e analisar imagens aéreas do solo em áreas urbanas por meio de uma câmera acoplada a um VANT com o objetivo de detectar alterações não autorizadas na terra, por exemplo, áreas de desmatamento. A etapa de processamento de imagens utilizou Redes Neurais Artificiais (RNA) baseadas na técnica chamada *Self Organizing Map* (SOM) através do algoritmo de *Kohonen*. Da mesma forma, em (MOTA et al., 2013) é utilizado o mesmo método para expandir as capacidades do VANT em estudo. O trabalho descrito em (MITISHITA et al., 2014) utiliza câmeras não-métricas para realização de levantamento fotogramétrico com uso de VANT em uma pequena região rural, cujas imagens foram capturadas pelo modelo de câmera *DSC-300* fabricada pela empresa *Sony Corporation*.

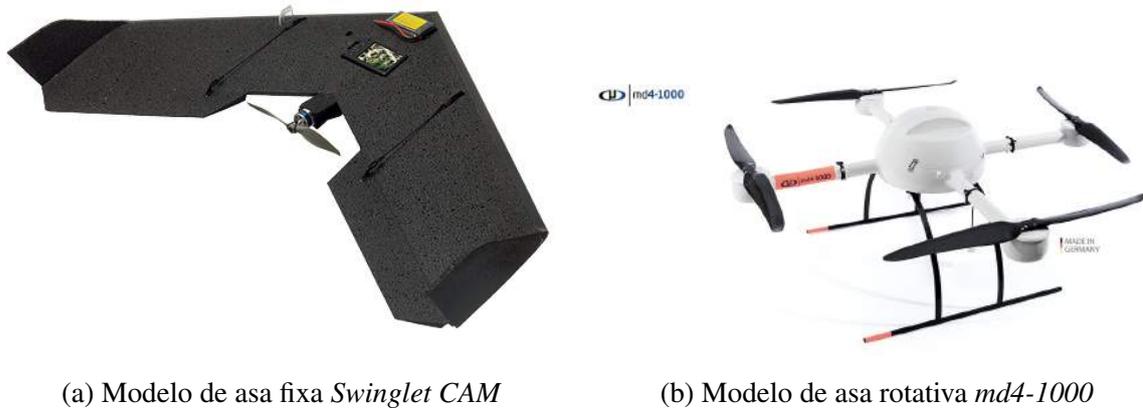
Em (AHMAD et al., 2013) é apresentada uma solução de baixo custo para a obtenção de imagens aéreas digitais, utilizadas em tarefas como o mapeamento temático e topográfico.

Utilizou-se o modelo de VANT *CropCam* produzido no Canadá, auto-guiado por GPS e cria as imagens digitais a partir de uma câmera de alta resolução, acessíveis dentro de algumas horas para análise. O sistema mostrou-se adequado para cobertura de áreas pequenas, sendo possível realizar o mapeamento de algumas situações, como o deslizamento de terras, erosão costeira, desmatamento ou mesmo para a geração de imagens para processamento por meio de Sistemas de Informações Geográficas (SIG) e agricultura. O sistema apenas faz a captação das imagens e não realiza qualquer tipo de processamento.

Os estudos abordados em (JÚNIOR; CÔRTEZ; FERREIRA, 2014) e (JÚNIOR et al., 2015) validam o uso de câmeras não-métricas para a obtenção de imagens aéreas visando a execução de tarefas relacionadas ao mapeamento da cobertura da terra a partir de VANT de pequeno porte. O modelo de asa fixa utilizado é o *Swinglet CAM* (Figura 2.2a) de fabricação suíça, que possui acoplada uma câmera de modelo *Canon IXUS 220HS* com resolução de 12,1 megapixels. A capacidade de voo do modelo é em média 30 minutos e possui, aproximadamente, 500 g de peso. Os trabalhos mostram que houve cobertura total e suficiente para geração de ortomosaicos, desde que utilizados pontos de apoio durante o imageamento utilizando câmeras fotográficas convencionais. O Instituto Nacional de Pesquisas da Amazônia (INPA) utiliza um VANT de pequeno porte para obtenção de dados florestais na Amazônia, especificamente na coleta de dados de sensoriamento remoto para estimar o nível de carbono na floresta através de câmeras e sensores acoplados. Utilizou-se o modelo quadricóptero *md4-1000* (Figura 2.2b), de fabricação alemã, com capacidade de voo para cerca de 80 minutos e 2.650g de peso (LEONEL, 2014). Segundo (EHSANI; MAJA, 2013) os veículos aéreos não tripulados são considerados de pequeno porte quando não excedem peso de 10 quilogramas.

A partir dos trabalhos apresentados, é possível perceber que não existe uma solução ideal para todas as tarefas de monitoramento ambiental e/ou agrícola. Alguns trabalhos, como os apresentados em (JORGE; BRANDÃO; INAMASU, 2014) e (URBAHS; JONAITE, 2013), visam à detecção de doenças na lavoura, porém, a solução utiliza sensores espectrais acoplados ao VANT o que aumenta os custos do projeto. Em (HERWITZ et al., 2004) o objetivo principal é a capacidade de coleta de imagens por um período prolongado em plantações de grandes proporções e com apoio de uma grande organização como a NASA não está preocupado com os custos envolvidos, pois a economia alcançada com uso do sistema é no-

Figura 2.2: Modelos de VANT de pequeno porte

(a) Modelo de asa fixa *Swinglet CAM*(b) Modelo de asa rotativa *md4-1000*

Fonte: Artefact and Landscape Studies Laboratory, University of Cyprus. Disponível em: <http://www.ucy.ac.cy/artlands/>. [Acesso em: 28/07/2015] (Fig. a) e Microdrones GMBH. Disponível em: <http://www.microdrones.com/en/products/md4-1000>. [Acesso em: 28/07/2015] (Fig. b).

toriamente superior aos grandes prejuízos causados pela falta dele; mesmo assim demandam altíssimo investimento para aplicações de médio e pequeno porte.

Um grande avanço para redução de custos em projetos com uso de VANT ocorreu a partir da popularização de câmeras não-métricas, que podem ser utilizadas até mesmo em trabalhos que requerem um nível de precisão considerável como a fotogrametria, por exemplo. Isso denota a possibilidade de uso destas câmeras em atividades mais simples como o monitoramento agrícola ou ambiental, principalmente em casos nos quais a fotointerpretação atende de forma suficiente os critérios qualitativos das análises. Os trabalhos de validação descritos em (JÚNIOR; CÔRTEZ; FERREIRA, 2014) sinalizam para a grande utilização de câmeras não-métricas, pois colaboram com a redução de custos em projetos com VANT e são facilmente encontradas no mercado. Por essa razão, a proposta desta dissertação também é justificada como uma solução de baixo custo por utilizar imagens exclusivamente obtidas por câmeras não métricas.

2.2 Formação de Imagens Digitais

A formação de imagens tem suas origens agrupadas em diversas categorias, entre elas as mais comumente utilizadas são as imagens formadas por uma fonte visual de luz, que cor-

respondem a uma estreita faixa do espectro eletromagnético. Porém, além dessa parte visível, existem sensores capazes de detectar luz a partir de outras fontes (RUSS, 2016), pelos quais pode-se citar a formação de imagens a partir de raios gama, raios-X e ultravioleta, que possuem comprimentos de ondas inferiores ao espectro visível. Por outro lado, imagens formadas a partir de luz infravermelha, micro-ondas e ondas de rádio correspondem a comprimentos de onda superiores ao espectro visível. Uma combinação de luz visível com outras fontes do espectro pode resultar em imagens para fins específicos, por exemplo, a luz visível combinada com infravermelho e dados de raios-X podem ser obtidas por telescópios em órbita. Outras categorias de formação de imagens envolvem a acústica (ultrassonografia, por exemplo) e ainda a microscopia eletrônica. Algumas aplicações e suas respectivas fontes de imagens são mostradas na Tabela 2.1, com base nas informações e exemplos extraídos de (GONZALEZ; WOODS, 2007) e (RUSS, 2016).

Tabela 2.1: Fonte de origem de imagens e principais áreas de aplicação

<i>Fonte de imagem</i>	<i>Sub-categoria</i>	<i>Áreas de aplicação</i>
Espectro Eletromagnético	Raios-gama	Medicina nuclear, Astronomia
	Raios-X	Diagnóstico médico, Indústria, Astronomia
	Ultravioleta	Investigação Forense, Ind., Astronomia
	Luz visível + Infravermelho	Microscopia, Sensoriamento Remoto
	Micro-ondas	Radar, Área miliar
	Rádio	Ressonância magnética, Astronomia
Acústica	-	Ultrassonografia, Microscopia, Exploração geológica (minérios e petróleo)
Microscopia Eletrônica	-	Imagem fractal

Uma Imagem pode ser definida como sendo uma representação de um objeto, podendo ser matematicamente compreendida como uma função bidimensional, $f(x, y)$, em que x e y são coordenadas espaciais, e a amplitude f corresponde ao nível de cinza, chamada intensidade, no ponto da coordenada x e y (GONZALEZ; WOODS, 2007).

Uma imagem digital é a representação de uma imagem bidimensional (ALKOFFASH et al., 2014) de modo que possa ser processada por meios eletrônicos. É obtida a partir do processo de conversão de dados contínuos, capturados através de sensores, para uma representação discreta. Os valores discretos extraídos são representados por um elemento básico da imagem digital, conhecido como pixel (SAHA; BASU; NASIPURI, 2014).

As imagens utilizadas neste trabalho tem como princípio de formação o espectro de luz visível. As outras formas de obtenção de imagens não serão exploradas porque este trabalho busca utilizar exclusivamente câmeras não-métricas visando à redução de custos, embora outros meios de imageamento proporcionem qualidade superior para o processamento de imagens, como por exemplo, o imageamento a partir do espectro de luz visível somado aos canais na faixa de infravermelho. Considerando a obtenção de imagens por meio de uma fonte do espectro de luz visível, a função $f(x, y)$, que representa uma imagem, é influenciada por uma quantidade de iluminação que incide no objeto (iluminação), expresso por $i(x, y)$ e por uma quantidade de iluminação refletida (refletância) expresso por $r(x, y)$. A combinação das componentes i e r representam uma imagem digital e pode ser expressa pela Equação 2.1.

$$f(x, y) = i(x, y) \cdot r(x, y) \quad (2.1)$$

Em que $i(x, y)$ representam a iluminação incidente no objeto e $r(x, y)$ a refletância.

A função $f(x, y)$ expressa na Equação 2.1, representa a intensidade de luz no ponto (x, y) , resultado do produto da quantidade de luz existente na cena onde o objeto foi capturado, representado por i , com a reflexão da luz por esse objeto, representado por r , ambos na mesma coordenada (x, y) da imagem. A representação de uma imagem digital $f(x, y)$ pode ser organizada em uma matriz, em que o pixel é o ponto de intersecção entre uma linha e uma coluna, que armazena o valor de intensidade de luz ou nível de cinza da respectiva coordenada.

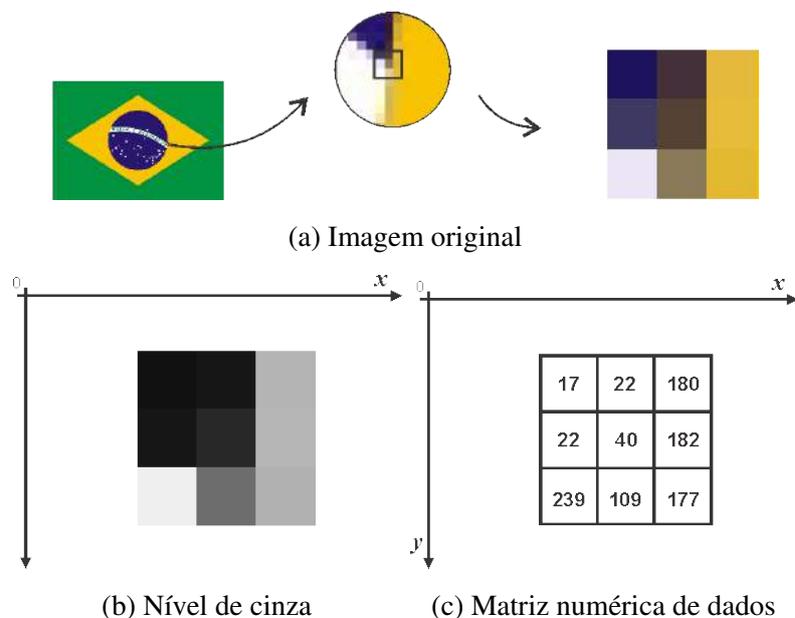
2.3 Processamento de Imagens

A área de processamento de imagens vem crescendo rapidamente e suas técnicas são utilizadas em uma ampla variedade de aplicações em diversas áreas do conhecimento, como na medicina, astronomia, biologia, automação industrial, sensoriamento remoto, microscopia, área militar e segurança pública, não existindo mais, praticamente, nenhuma área de empreendimento técnico que não seja impactada de uma forma ou de outra pelo processamento digital de imagens (GONZALEZ; WOODS, 2007).

O processamento digital de imagens consiste em um conjunto de técnicas para capturar,

representar e transformar imagens com o auxílio do computador (PEDRINI; SCHWARTZ, 2007). A entrada e a saída de um sistema de processamento de imagens digitais são imagens digitais (PITAS, 2000) e o objetivo principal na tarefa do processamento é encontrar as características da imagem, reconhecer um objeto ou pontos de interesse (CAMPOY et al., 2009). A imagem digitalizada é constituída por uma matriz numérica de dados, a qual será processada pelo computador para extrair as informações desejadas da imagem, de modo que tudo que o computador interpreta é uma matriz de números (BRADSKI; KAEBLER, 2008). A Figura 2.3 apresenta a ampliação de parte de uma imagem digital até que seja possível a visualização dos pixels correspondentes à área de uma matriz de 3×3 , onde na Figura 2.3b esta área é apresentada em tons de cinza no formato de uma matriz bidimensional, cuja matriz numérica correspondente é mostrada na Figura 2.3c, que representa os respectivos valores da intensidade de nível cinza encontrados nos pixels representados na imagem original. Considerando uma imagem de 8 bits, por exemplo, é possível encontrar 2^8 , ou 256 possibilidades de valores de intensidade de pixel, compreendidos entre o intervalo 0-255. O valor 0 (zero) está relacionado ao nível de cinza mais escuro (preto), enquanto que o valor 255 está relacionado ao nível de cinza mais claro (branco), valores intermediários representam variados níveis de cinza.

Figura 2.3: Representação de uma imagem digital em nível de pixel



Fonte: Próprio autor.

2.3.1 Pré-processamento

A etapa de pré-processamento tem por objetivo melhorar a imagem e buscar aumentar as chances de sucesso das etapas seguintes, sendo de grande importância por preparar a imagem para efeitos de interpretação humana ou tratá-la para que o processamento, armazenamento, representação ou transmissão, ocorra satisfatoriamente (ALKOFFASH et al., 2014). Em algumas técnicas de processamento, por exemplo, é necessário reduzir a quantidade de canais, facilitando as etapas futuras e reduzindo o custo computacional. Uma das técnicas utilizadas neste trabalho é a conversão da imagem em tons de cinza, que consiste na transformação dos canais originais da imagem em apenas um único canal. Considerando uma imagem baseada no canais vermelho, verde e azul, conhecido como o padrão *Red, Green and Blue* (RGB), o valor de cada pixel pode ser convertido em tons de cinza a partir da média ponderada das componentes RGB, de acordo com a Equação 2.2.

$$C(x, y) = R \cdot 0,2999 + G \cdot 0,587 + B \cdot 0,114 \quad (2.2)$$

A imagem é finalmente convertida em escala de cinza quando o valor $C(x, y)$ é atribuído para os componentes RGB de cada ponto $f(x, y)$ da imagem original. Esta etapa de conversão é utilizada em uma das abordagens propostas nesta dissertação, a partir do qual ocorre a conversão dos três canais RGB originalmente obtidos para escala de cinza.

2.3.2 Segmentação de imagens por limiarização

A etapa de segmentação de imagens consiste no agrupamento de um conjunto de elementos com as mesmas características, subdividindo a imagem em regiões ou objetos de interesse (BALA, 2012). É considerada de grande importância nas tarefas de análise de imagem, pois contribui para o bom desempenho das etapas seguintes como, por exemplo, o reconhecimento e classificação de imagens. Em geral, quanto mais precisa a segmentação, maiores as chances de sucesso na identificação de regiões de interesse da imagem (GONZALEZ; WOODS, 2007). De acordo com o autor, os algoritmos de segmentação são divididos de acordo com duas propriedades básicas: descontinuidade e similaridade. A primeira abordagem baseia-se na segmentação por mudanças abruptas de intensidade, como a detecção de bordas, por exemplo. A segunda abordagem é baseada na divisão da imagem em regiões de

acordo com a similaridade pré-definida por um conjunto de critérios.

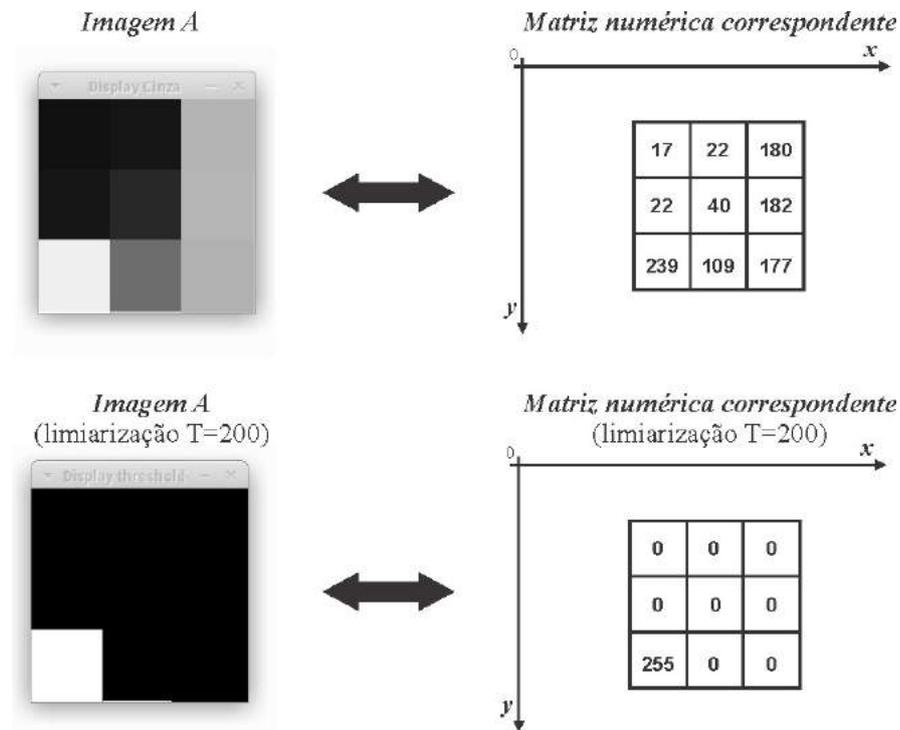
A técnica de limiarização é bastante empregada em aplicações de segmentação de imagens devido as suas propriedades intuitivas e simplicidade de implementação, culminando um processo sem esforço computacional. Consiste em agrupar os níveis de cinza e é descrita em (ROSIN; IOANNIDIS, 2003), de modo que a imagem formada é composta por objetos claros sobre um fundo escuro de tal forma que os pixels do objeto e do fundo tenham valores de intensidade representados em dois grupos dominantes. Conforme explica (LIM; LEE, 1990), o objetivo da limiarização aplicada em imagens monocromáticas é separar objetos individuais em uma imagem. Uma maneira simples de extrair os objetos de interesse em uma imagem é selecionar um limiar T , que separa a imagem em dois grupos, então, qualquer ponto (x, y) na imagem em que $f(x, y) > T$ é chamado ponto do objeto; caso contrário é chamado de ponto de fundo; assim é possível realçar objetos ou regiões de interesse em uma imagem.

A separação da imagem em duas regiões consiste em determinar um valor de limiar T de modo que pixels com níveis de cinza inferiores ao limiar estabelecido serão transformados no valor R_1 , enquanto que pixels com valores superiores ao limiar T serão modificados para o valor R_2 definido de acordo com a Equação 2.3 (GONZALEZ; WOODS, 2007).

$$g(x, y) = \begin{cases} R_1, & \text{se } f(x, y) \leq T \\ R_2, & \text{se } f(x, y) > T \end{cases} \quad (2.3)$$

R_1 e R_2 são valores pré-estabelecidos para o nível de cinza desejado na imagem de saída, normalmente é utilizado o valor 0 (preto) e 255 (branco).

O processo descrito na Equação 2.3 é chamado de limiarização global, pois os valores de limiar T são definidos pela função para uma imagem inteira. A imagem apresentada na Figura 2.4, por exemplo, ilustra uma imagem com pixels em diferentes níveis de intensidade de cinza conforme sua matriz numérica correspondente. Aplicando ao exemplo um limiar $T = 200$, os pixels cujo valor é inferior ao limiar T estabelecido são transformados para o valor 0 (zero) representado pela cor preta, enquanto que pixels com valores superiores ao limiar T estabelecido são transformados para o valor 255, representados pela cor branca, resultando no processo demonstrado na Figura 2.4.

Figura 2.4: Processo de limiarização em imagem com valor $T = 200$ 

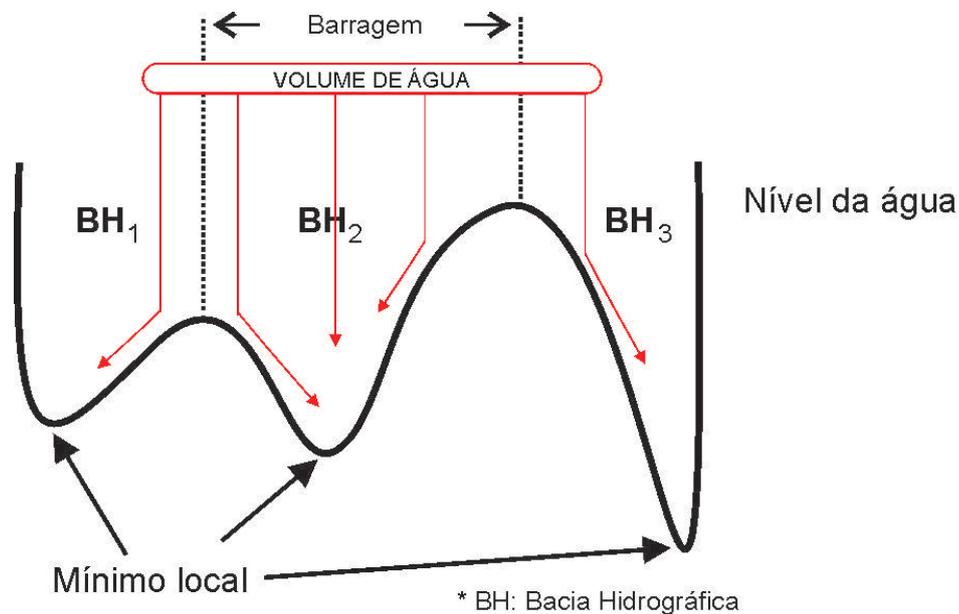
Fonte: Próprio autor.

2.3.3 Segmentação baseada em *Watershed*

A transformada *Watershed* é uma ferramenta baseada em morfologia matemática para segmentação de imagens (MEYER, 1994). Foi inicialmente proposto por Digabel e Lantuejoul em 1977 (BEUCHER; LANTUEJOL, 1979) e melhorado por Li et. al em 2003 (BALA, 2012). Baseia-se na visualização de uma imagem em três dimensões, similar a uma superfície topográfica, onde as duas coordenadas espaciais x, y de uma imagem são observadas e a altura representa o nível de cinza do pixel correspondente (BIENIEK; MOGA, 2000). A partir desta interpretação "topográfica" são considerados três tipos de pontos: pontos que representam a região mínima (a), pontos em que se um volume de água for colocado cairia com segurança nestes mínimos locais (b) e pontos propensos a cair em mais de um mínimo local considerado. Imaginando uma bacia hidrográfica em que manchas claras e escuras representam colinas e depressões em uma paisagem (BLEAU; LEON, 2000), onde o volume de água inserido causa a inundação dos mínimos locais da paisagem, quando o nível da água atingir o pico mais alto o processo é interrompido, resultando em uma paisagem dividida

em regiões ou bacias separadas por barragens, chamadas linhas de divisão das *watersheds* que estão representando fronteiras extraídas pelo algoritmo de segmentação. A Figura 2.5 apresenta uma demonstração do processo de imersão da transformada *watershed*.

Figura 2.5: Ilustração do processo de imersão da transformada *watershed*



Fonte: Adaptado de (BALA, 2012)

O algoritmo *watershed* geralmente é utilizado em imagens de gradiente para detectar as bacias hidrográficas e todos os mínimos locais da imagem. Para isso, em alguns problemas outros passos são necessários para realizar a segmentação, por exemplo, transformação em escala de cinza e limiarização são possíveis métodos que podem anteceder a segmentação baseada em *watershed*. Além disso, a presença de técnicas de dilatação de pixel e métodos iterativos são relatadas em alguns trabalhos (BIENIECKI, 2004) que utilizam esta abordagem.

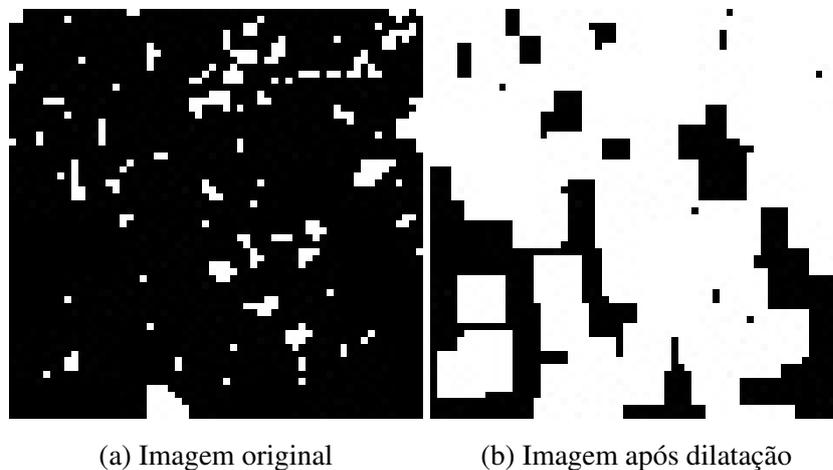
O processo de dilatação é uma das técnicas básicas da morfologia matemática onde a operação está relacionada com pixels vizinhos e tem o objetivo alargar regiões mais claras e reduzir regiões escuras na imagem. A definição formal da etapa de dilatação é dada através da Equação 2.4. A dilatação de A por B é o conjunto de todos os deslocamentos z de forma que \hat{B} e A se sobreponham pelo menos por um elemento (GONZALEZ; WOODS, 2007). O elemento estruturante é entendido como o conjunto bem definido e conhecido, capaz de gerar informações através da transformação a um conjunto desconhecido (WANGENHEIM; SANTOS; SOUZA, 1998).

$$A \oplus B = \{z \mid (\hat{B}_z) \cap A \neq \phi\} \quad (2.4)$$

$A \oplus B$ representa a dilatação de A por B.

A Figura 2.6a mostra os resultados de parte de uma imagem com aplicação da função dilatação. As imagens utilizadas nesta etapa devem ser imagens binárias ou em tons de cinza (MEDEIROS, 2003). Os resultados alcançados com o operador de dilatação permite preencher espaços vazios, conectar objetos próximos na imagem e, dependendo da aplicação, podem amenizar ruídos presentes na imagem.

Figura 2.6: Resultado da etapa de dilatação de imagem



Fonte: Próprio autor.

As imagens em gradiente podem ser geradas pela técnica de transformada de distância, descrito em (BORGEFORS, 1986). Uma transformação de distância converte uma imagem binária em uma imagem com vários níveis de cinza, de modo que todos os *pixels* possuam um valor correspondente à característica do pixel vizinho.

Considerando que o objetivo deste trabalho é a identificação de áreas de solo exposto na vegetação, a marcação da base das bacias hidrográficas é suficiente para iniciar o processo de identificação das falhas. Neste cenário não é necessário a divisão das barragens com as linhas de *Watershed*, mas a segmentação das bases que correspondem às áreas de degradação. Nesse contexto, a implementação do algoritmo original de *Watershed* é interrompido na etapa que ocorre a formação das bases das barragens, possibilitando a identificação de solo

exposto. As técnicas de transformação de distância, dilatação e limiarização são empregadas em etapas seguintes e visam melhorar a qualidade da segmentação.

2.4 Processamentos de Imagens coloridas no contexto agrícola

O processamento a partir de imagens coloridas podem garantir um melhor resultado das etapas de segmentação, pois vários canais são utilizados aumentando as chances de sucesso durante o processamento. A obtenção de imagens aéreas em uma região agrícola é uma poderosa ferramenta para obtenção de dados precisos dispensando a necessidade de percorrer até o local desejado para analisar áreas de interesse. Atualmente existem diversas técnicas, a maioria delas provenientes do sensoriamento remoto, para a classificação de imagens aplicado ao contexto agrícola ou monitoramento ambiental. Alguns trabalhos abordam a captação de imagens utilizando várias bandas, como o uso de sistemas de sensores Hyperespectrais (UTO et al., 2013) composto por 121 canais capaz de identificar níveis de clorofilas através do índice *Normalized Difference Vegetation Index* (NDVI). O uso de imagens capturadas através do formato de cores RGB (*Red, Green, Blue*) é frequente, pois são facilmente obtidas por câmeras não-métricas de baixo custo que acopladas a VANT permitem realizar atividades de imageamento aéreo de plantios (ALVES; FERREIRA; GALLIS, 2015)(JÚNIOR et al., 2015).

2.4.1 Espaço de cores RGB e HSI

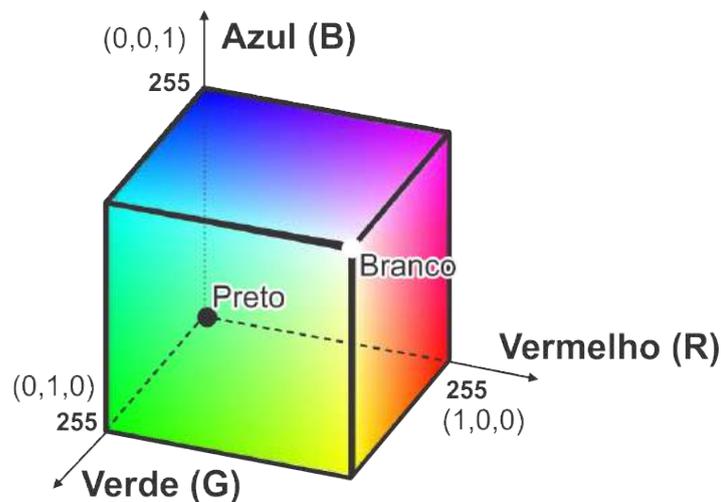
Os espaços de cores normalmente são criados por motivos práticos e por isso há vários padrões diferentes (FORSYTH; PONCE, 2012). O espaço de cores dos canais RGB é amplamente utilizado em todo o mundo, pois são facilmente obtidas por câmeras de baixo custo e podem ser usadas para diversas finalidades. O espaço RGB é padronizado pela ISO 17321 que trata da caracterização de cores das câmeras fotográficas digitais, cuja transformação realizadas pelo sensor são definidos na norma (SUSSTRUNK; BUCKLEY; SWEN, 1999). As cores primárias do modelo RGB são vermelho (*Red*), verde (*Green*) e azul (*Blue*).

O modelo RGB é baseado em um sistema de coordenadas cartesianas em três dimensões

representado pelo cubo apresentado na Figura 2.7. Cada cor é representada por um ponto na superfície ou no interior deste cubo. A escala de cinza pode ser localizada na diagonal que une a cor preta até a cor branca do cubo. O intervalo de cores RGB em relação aos níveis de cinza compreende (0,0,0) até (255,255,255) que representam respectivamente as cores preto e branco. As cores intermediárias representam os níveis de cinza de cada atributo. Por convenção, assume-se que os valores das cores foram normalizados, de forma que o cubo da Figura 2.7 apresente valores entre o intervalo [0,1].

Considerando que em uma imagem RGB cada uma das cores (R, G e B) representa uma imagem de 8 bits, podemos afirmar que cada pixel de cores RGB tem profundidade de 24 bits, pois carregam três planos de imagem de 8 bits cada. Dessa forma tem-se $(2^8)^3 = 16.777.216$ possibilidades de cores para cada pixel em uma imagem de 24 bits. Da mesma forma que as imagens monocromáticas cada plano do espaço RGB carrega informações de nível cinza compreendidos entre o intervalo [0-255].

Figura 2.7: Representação do espaço de cores RGB



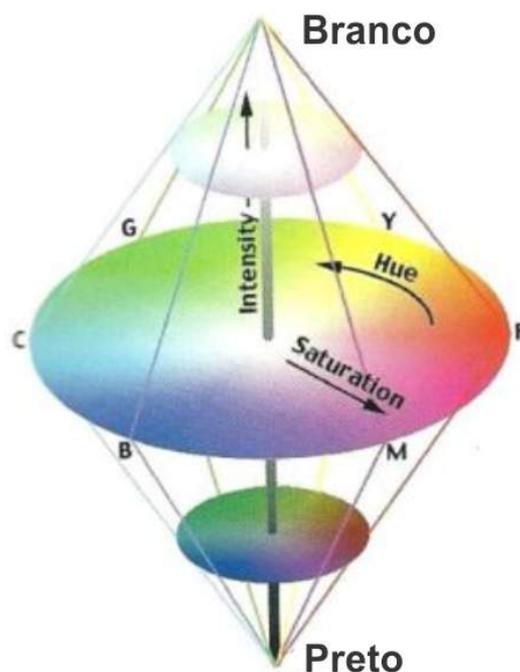
Fonte: Adaptado de (BLOTTA et al., 2011)

Uma limitação do espaço de cores RGB, em relação à captura de imagens através do espectro de luz visível, está relacionada ao tratamento das informações de brilho, que estão contidas em cada componente de acordo com as condições de luminosidade do ambiente. O processamento de imagens pode sofrer interferências indesejáveis devido a impossibilidade de desprezar à variação de luminosidade com uso desse espaço. Uma solução possível para o problema de variação de luminosidade é a utilização do espaço de cores *Hue, Saturation, Intensity* (HSI), relacionados respectivamente aos níveis de tonalidade, saturação e intensidade

de brilho. O espaço de cores HSI corresponde aproximadamente à forma como os humanos percebem e descrevem a cor. (GONZALEZ; WOODS, 2007)(MANJUNATH et al., 2001).

A tonalidade (H) é um atributo que representa a cor pura, que ao adicionar branco a esta cor pura, alteramos o parâmetro de saturação (S), de forma que quanto menos adição de branco, mais saturada a cor será (MANJUNATH et al., 2001). A informação (I) corresponde à intensidade de brilho da cor. A representação do espaço de cores HSI é feita a partir de um cone duplo, representado na Figura 2.8, em que o centro é uma circunferência dividida em ângulos de igual tamanho, distribuindo os níveis de intensidade da componente *Hue* (H) entre 0 e 2π . A distância do centro da circunferência até a borda diz respeito à componente *Saturation* (S) e varia entre 0 e 1. O eixo perpendicular à circunferência se refere à *Intensity* (I) e varia entre 0 (preto) e 1 (branco), indicando a quantidade de luz presente na cor.

Figura 2.8: Representação do espaço de cores HSI



Fonte: Adaptado de (BLOTTA et al., 2011)

A conversão do espaço de cores RGB em HSI utiliza uma metodologia simples e computacionalmente leve, podendo ser aplicada a vários tipos de problemas, como aprimoramento de imagens médicas (BLOTTA et al., 2011), identificação de deslizamentos de terras (LI et al., 2014) e solução de problemas relacionados à distorção de cores em vídeos (YANHUI et al., 2013). É um processo totalmente reversível, podendo garantir resultados aceitáveis.

Considerando o problema de classificar áreas de interesse em ambientes externos, a separação da componente de intensidade de brilho (I) das informações intrínsecas de cor (H) e (S), podem amenizar os efeitos da luminosidade presente durante a aquisição das imagens. A conversão entre o espaço de cor RGB e a componente *Hue* (H) é dada a partir da equação 2.5, em que o valor θ é encontrado a partir da Equação 2.6. Enquanto que as Equações 2.7 e 2.8 mostram as relações para a conversão do espaço RGB e as componentes *Saturation* (S) e *Intensity* (I) do espaço de cores HSI.

$$H = \begin{cases} \theta, & \text{se } B \leq G \\ 360 - \theta, & \text{se } B > G \end{cases} \quad (2.5)$$

$$\theta = \cos^{-1} \left\{ \frac{1/2[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{\frac{1}{2}}} \right\} \quad (2.6)$$

$$S = 1 - \frac{3}{(R + G + B)} [\min(R, G, B)] \quad (2.7)$$

$$I = \frac{1}{3}(R + G + B) \quad (2.8)$$

Este trabalho faz uso de câmeras não-métricas que formam imagens sob o espaço de cores RGB. A conversão para o espaço de cores HSI é empregada em uma das técnicas apresentadas, que realiza a segmentação considerando os três canais de cores e tem por objetivo reduzir os efeitos da variação de luminosidade presente durante a captura das imagens. A variação de luminosidade pode ocorrer por diversos motivos, entre eles podemos citar a diferença de horários em que as imagens são obtidas, variação do ângulo da câmera decorrente de movimentos do VANT ou até mesmo pelos efeitos de sombreamento ocasionados por nuvens que interferem na luminosidade natural do ambiente.

2.4.2 Técnicas de Aprendizagem de Máquina

Aprendizagem de máquina (AM) é uma subárea do campo da inteligência artificial (IA) que estuda técnicas que tornam o computador capaz de aprender a executar determinada tarefa a partir de experiências e pode ser aplicada em diversas áreas do conhecimento. Aplicados à visão computacional, técnicas de AM permitem a automação no processo de identificação, eliminando alguns problemas de natureza humana, como mostra (BONIECKI et al., 2015) ao citar prováveis erros relacionados à subjetividade da avaliação, fadiga e outros fatores que geram erros na observação feita por um ser humano.

Técnicas de AM podem ser divididas em dois grupos: aprendizagem supervisionada e não-supervisionada. Segundo Russel (RUSSELL; NORVIG, 2009), a aprendizagem é dita supervisionada quando o agente observa alguns exemplos de entrada e aprende uma função que faz o mapeamento da entrada para a saída, enquanto que nas técnicas de aprendizagem não-supervisionada, o agente aprende os padrões de entrada, embora não seja fornecido nenhum *feedback* explícito. Desta forma, em uma classificação supervisionada utiliza-se um conjunto de treinamento para a classificação de novos atributos desconhecidos.

Problemas relacionados ao reconhecimento de padrões, sobretudo aos casos aplicados à agricultura e ao processamento de imagens aéreas, podem ser resolvidos por meio de técnicas de classificação supervisionada (FILIFE; GON, 2014), (LEWIS; PHINN; ARROYO, 2013). Uma técnica comum baseia-se em regras de distância como a aplicação de algoritmos baseados em técnicas do vizinho mais próximo, conhecido como *Nearest neighbor* (NN), proposto em 1967 pelos pesquisadores T. M. Cover e P. E. Hart (COVER; HART, 1967).

2.4.3 Classificação baseada na regra do 1-vizinho mais próximo

A regra do vizinho mais próximo (NN) identifica a classe de um ponto de dados desconhecido de acordo com o valor de seu vizinho mais próximo em relação a um conjunto de dados cujas classes são conhecidas. Técnicas baseadas em NN utilizam uma abordagem de aprendizagem supervisionada e pode ser aplicada em diversos problemas do cotidiano, inclusive nas aplicações de reconhecimento. Concomitantemente, a técnica *k-Nearest Neighbor* (*k-NN*) define a classe da amostra de dados a ser considerada baseando-se em *k* vizinhos mais próximos do conjunto de treinamento. Segundo (CHÁVEZ et al., 2015), um classificador

baseado em *k-Nearest Neighbor* utiliza dados de treinamento quando uma nova instância é criada com uso de uma medida de distância para procurar os k registros mais próximos do novo registro, ou seja, o novo registro é classificado a partir de uma medida de similaridade.

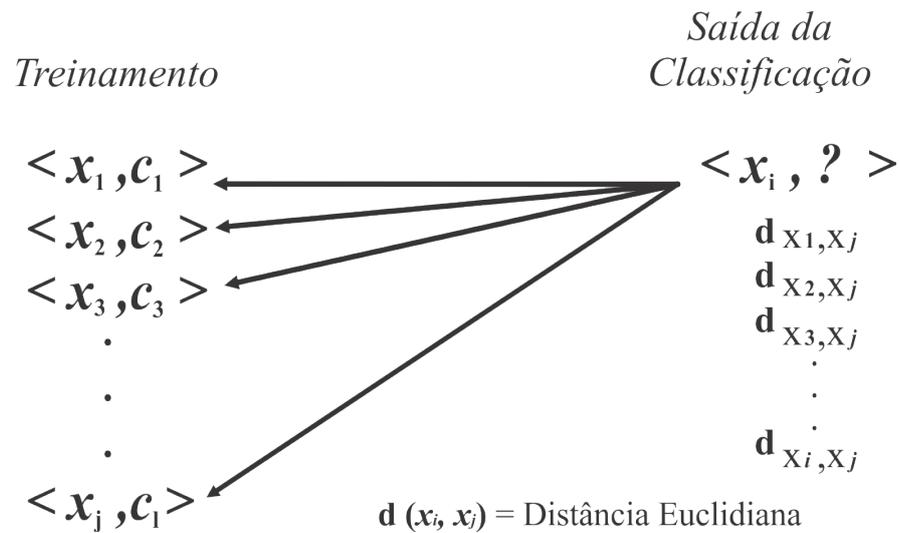
O método 1-vizinho mais próximo (*1-NN*) é admissível e considerado um método simples e eficiente de classificação (COVER; HART, 1967), (BHATIA; VANDANA, 2010) e não há custo computacional relacionado ao treinamento (ABULEIL; TAYLOR; MOUSSA, 2015). A regra do *1-NN* pode calcular a distância de um objeto para seus vizinhos do conjunto de treinamento baseado em diversas métricas de distância. A medida baseada na distância Euclidiana é o método mais popular e amplamente utilizado. Na fase de treinamento, o algoritmo memoriza os exemplos rotulados do conjunto de treinamento (FACELI et al., 2011). Desta forma, a instância desconhecida será comparada com todas as instâncias previamente conhecidas (definidos em um conjunto de treinamento), de forma que a classe da menor distância Euclidiana encontrada definirá a classe antes desconhecida. A distância Euclidiana d entre dois objetos x_i e x_j , representados por vetores no espaço \mathbb{R}^d , em que x_i^l e x_j^l são elementos desses vetores e correspondem aos valores das coordenadas l (instâncias), é dada pela Equação 2.9 (FACELI et al., 2011).

$$D(x_i, x_j) = \sqrt{\sum_{l=1}^d (x_i^l - x_j^l)^2} \quad (2.9)$$

O processo de classificação é ilustrado na Figura 2.9, considerando x_i as instâncias do objeto a ser classificados e x_j as instâncias do conjunto de treinamento, a classe C_l de menor distância euclidiana $d(x_i, x_j)$ encontrada entre x_i e todas as instâncias de treinamento X_j será a classe determinada para o elemento a ser classificado. A cada novo pixel a ser classificado o processo é repetido para todos os dados do conjunto de treinamento.

A técnica baseada em 1-NN é empregada em uma das abordagens utilizadas neste trabalho e tem por objetivo dispensar a necessidade de interferência humana para a definição de alguns parâmetros, como ocorre com uso da técnica baseada em *watershed*, em que necessita-se da definição prévia de dois limiares a cada sobrevoo na área do imageamento. Ao contrário, a abordagem utilizando aprendizagem de máquina faz uso de um conjunto de treinamento que conterá informações sobre os níveis de RGB dos *pixels* selecionados da

Figura 2.9: Processo de aprendizagem baseado em instâncias



Fonte: Próprio autor.

imagem. Esta técnica associada à conversão entre o espaço de cores RGB e HSI contribui para a realização de tarefas cada vez mais autônomas executadas por um VANT. Outras técnicas mais avançadas presentes no campo da inteligência artificial poderiam ser utilizadas para garantir melhor classificação de novos conjuntos de *pixels*, mas as abordagens propostas neste trabalho pretendem fazer uso de técnicas simples e computacionalmente de menor custo, tendo em vista que serão implantadas em computadores de pequeno porte e baixo consumo de energia. Isso justifica o uso inicial da abordagem com imagens em tons de cinza e uso do algoritmo baseado em *watershed*, pois tornam o processamento menos custoso. A progressão para o uso dos três canais de imagem (RGB) é um passo importante para agregar mais qualidade na segmentação e garantir maior independência no processo de tomada de decisão, apesar de provavelmente apresentar maior custo computacional. Esta dissertação pretende discutir todos esses aspectos de processamento de imagens com o objetivo de analisar a viabilidade de uso dos algoritmos propostos implantados em sistemas embarcados.

Capítulo 3

Sistemas Embarcados

Neste capítulo são apresentados conceitos e definições sobre arquitetura de computadores com ênfase em sistemas embarcados, especificamente os de arquitetura x86 (CISC) e ARM (RISC). Alguns conceitos importantes são apresentados e as principais métricas de projeto são exibidas na Seção 3.1. A Subseção 3.1.1 é criada para abordar características de soluções em tempo real. A Seção 3.2 apresenta alguns trabalhos com uso de sistemas embarcados acoplados em VANT para a realização de algumas tarefas. A Seção 3.3 apresenta as principais características de processadores, ressaltando as particularidades da arquitetura CISC e RISC (Subseção 3.3.1) e critérios de *software* em sistemas embarcados (Subseção 3.4). Por fim, a Seção 3.5 apresenta as características dos sistemas embarcados utilizados neste trabalho.

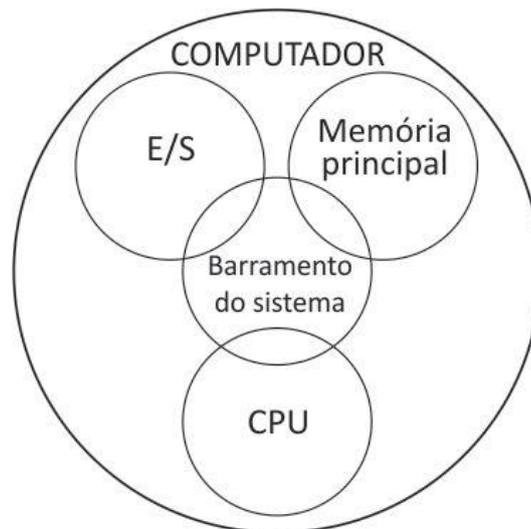
3.1 Conceitos e visão geral

Sistemas embarcados fazem parte de diversas atividades do cotidiano, praticamente estão presentes em todos os dispositivos eletrônicos, como por exemplo, câmeras fotográficas, roteadores sem fio, GPS automotivo, injeção eletrônica, celulares, televisores, controle remoto e uma série de outros dispositivos. Um sistema embarcado é definido como sendo a combinação de *hardware* e *software* de computador, e talvez partes mecânicas e outras, projetada para realizar uma função dedicada e, normalmente, faz parte de um sistema maior (STALLINGS, 2010), (SALCIC; RADOJEVIC, 2011).

Em geral, computadores embarcados possuem a mesma estrutura dos computadores pessoais, inclusive com a presença comum de alguns componentes para a realização das etapas

de processamento, armazenamento e comunicação de dados. Estes componentes se referem à unidade central de processamento (CPU), memória principal e interface Entrada/Saída (E/S). A conexão destes três elementos é realizada a partir de um mecanismo de interconexão denominado barramento do sistema. A Figura 3.1 apresenta uma estrutura básica comum para qualquer tipo de computador.

Figura 3.1: Estrutura básica de um computador



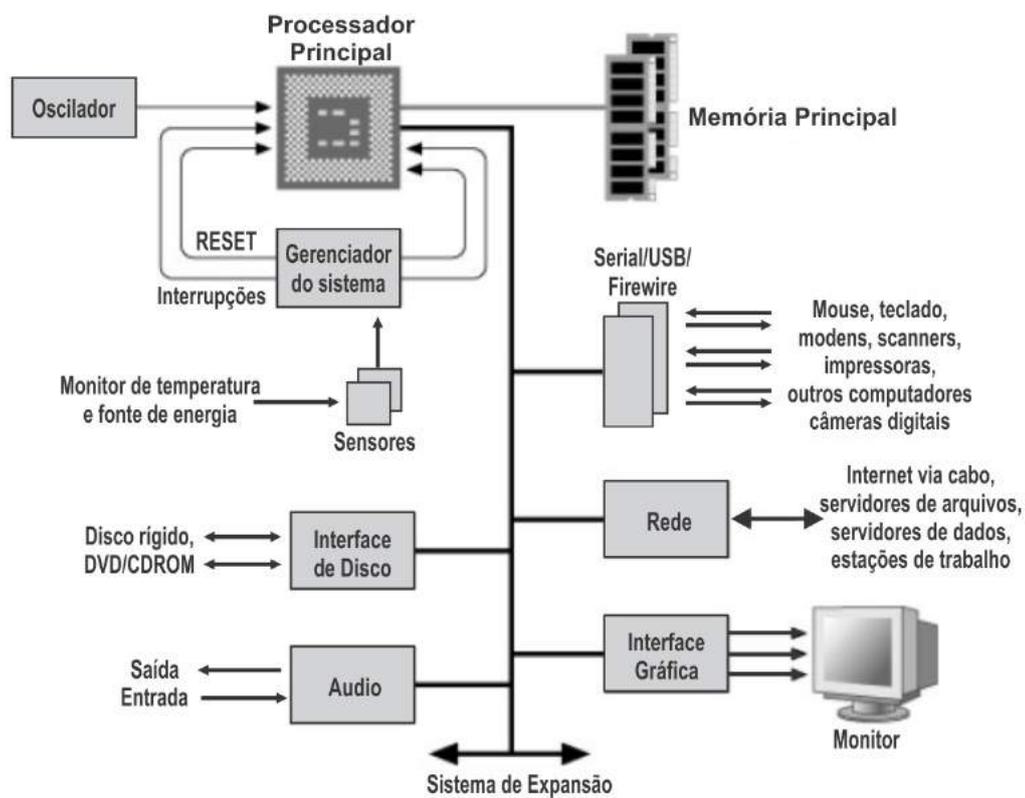
Fonte: Adaptado de (STALLINGS, 2010)

A diferença primária entre um computador embarcado e um computador pessoal ocorre no propósito da aplicação para o qual foram projetados. O primeiro é dedicado a realizar tarefas específicas por meio de *hardware* e *software* com funções fixas, enquanto que o segundo é capaz de realizar uma grande variedade de tarefas e aplicações. Outras especificidades em relação ao computador embarcado são citadas em (KOOPMAN, 1996) como a interface humana que pode ser uma simples luz piscando ou mais complexa como a visão robótica em tempo real, a capacidade de realizar diagnósticos do sistema que está sendo controlado não se restringindo ao controle do próprio hardware, ou ainda podem possuir um hardware programável baseado em *Field Programmable Gate Array* (FPGA) para uma aplicação específica.

Computadores pessoais demandam grande poder computacional, e por isso requerem processadores rápidos e eficientes, além de elevada quantidade de memória principal para executar e gerenciar uma grande variedade de tarefas simultaneamente. Tal demanda é justificada em (CATSOULIS, 2005) que cita a necessidade de armazenar o sistema operacional,

gerenciar diversos aplicativos, controlar a interface para dispositivos de armazenamento em massa, monitorar temperatura e níveis de tensão dos componentes por meio de sensores. Além disso, os computadores pessoais são dotados de muitos dispositivos de controle E/S para manipulação do usuário como, por exemplo, teclado, mouse, interface de áudio, monitor e prover conectividade (interface de rede e periféricos). O diagrama em blocos de um computador pessoal é visto na Figura 3.2.

Figura 3.2: Diagrama em blocos de um computador convencional

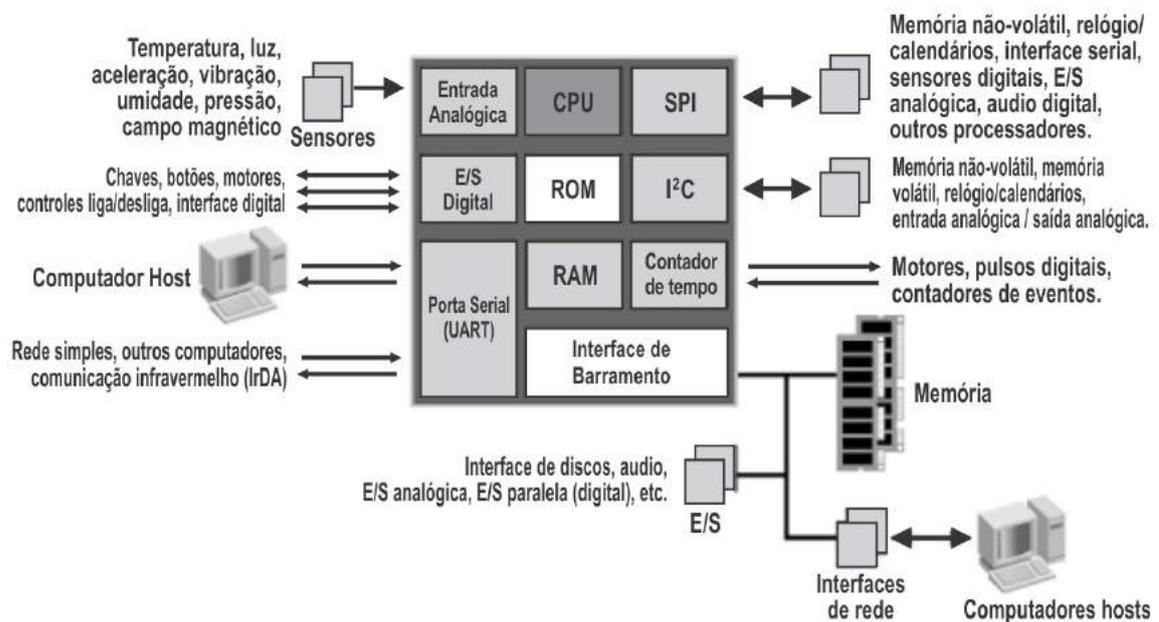


Fonte: Adaptado de (CATSOULIS, 2005)

Considerando a organização do hardware, os sistemas embarcados de alto desempenho não são diferentes de um computador convencional. Os sistemas embarcados de menor porte executam funções similares a um processador, incorporando algumas funcionalidades através de um único chip, a exemplo dos microcontroladores. Estes possuem internamente uma CPU e uma pequena quantidade de memória interna para executar suas tarefas, cuja função primordial é o controle dos módulos de Entrada/Saída (E/S), que são normalmente de propósito geral, conhecidos como *General-purpose input/output* (GPIO). O acionamento de recursos usando a porta GPIO é efetuado em ocasiões que necessitem do acionamento de al-

gum dispositivo ou para interpretação de dados externos recebidos por estas portas. Existem diversas tipos e uma crescente lista de bases de arquitetura de processadores que podem ser utilizados em sistemas embarcados, desde os mais simples que utilizam microprocessadores de pequeno porte de 8 a 16 bits, até os sistemas com microcontroladores ou microprocessadores de 32 bits considerados de grande porte. Estes últimos são principalmente utilizados em aplicações de tempo real e, normalmente, utilizam um sistema operacional, embora haja uma tendência de utilização de sistemas em tempo real em processadores de menor porte (TAN; ANH, 2009). A Figura 3.3 apresenta o diagrama em blocos de um sistema embarcado.

Figura 3.3: Diagrama em blocos de um sistema embarcado



Fonte: Adaptado de (CATSOULIS, 2005)

O grande desafio em um projeto de sistemas embarcados é a realização de um projeto que possa atender simultaneamente ao maior número de métricas possíveis, cujas principais são descritas a seguir.

- **Custo:** Dividido em custo por unidade e custo de engenharia não-recorrente (NRE). O primeiro trata do custo de produção de uma unidade, enquanto que o NRE trata do custo fixo necessário para projetar o sistema, não dependendo da quantidade de unidades produzidas.
- **Tamanho:** Está relacionado ao tamanho do espaço físico ocupado pelo hardware de-

envolvido, inclusive em relação a seus componentes.

- Desempenho: Medido pelo tempo de execução ou rendimento do sistema.
- Vazão: Quantidade de tarefas por unidade de tempo.
- Consumo de energia: Quantidade de energia consumida pelo sistema. Influencia na autonomia de baterias e no resfriamento do sistema.
- Flexibilidade: Capacidade de alterar funcionalidades do sistema sem envolver custos de NRE.
- Tempo de prototipagem: Tempo necessário para projetar uma versão funcional do sistema, podendo ser superior ao tempo produção da linha final, envolve também o tempo para realização de testes da solução.
- Manutenção: Capacidade de modificar o sistema após o lançamento inicial.

As métricas apresentadas normalmente são conflitantes e necessitam de caráter subjetivo de avaliação para melhor adequação do sistema proposto. É preciso analisar cada caso e priorizar as métricas mais relevantes para buscar um projeto eficiente.

Quanto à arquitetura do computador, duas abordagens principais são verificadas: a primeira relacionada aos computadores com conjunto complexo de instruções (CISC), como por exemplo, os sistemas x86 e a segunda trata de computadores com conjunto reduzido de instruções (RISC), como por exemplo, sistemas baseados em ARM amplamente utilizado em sistemas embarcados. Estas abordagens serão detalhadas na Seção 3.3.

3.1.1 Sistemas em tempo real

A definição canônica de Donald Gillies afirma que um sistema em tempo real é aquele cuja precisão de resultados não dependem apenas da exatidão do cálculo lógico, mas também o momento em que o resultado é produzido, pois se as restrições de tempo do sistema não forem cumpridas, caracteriza-se uma falha do sistema ocorrida (GILLIES, 1998), ou seja, independentemente da tarefa realizada pela aplicação de tempo real, além de ser executada corretamente, precisa ser concluída em um tempo hábil.

Sistemas embarcados possuem a capacidade de trabalhar a uma velocidade imposta pelo ambiente, em geral devem garantir uma operação em tempo real reativo a eventos externos, garantindo que o sistema continuamente reaja aos estímulos recebidos do ambiente. O sentido de tempo real não deve ser associado à capacidade de plataformas de *hardware* de maior desempenho que sejam capazes de entregar o resultado em menor tempo. Ao contrário, deve está relacionada à garantia da entrega do resultado em um tempo determinado, mesmo com *hardware* mais lento e mais barato. Portanto, o processamento em tempo real exige um nível de previsibilidade do sistema que a suporta, cujo objetivo é garantir o comportamento em tempo hábil ao interagir com o mundo físico (YAGHMOUR et al., 2008).

O processamento de sinais em missões críticas são exemplos de sistemas que requerem significativa operação em tempo real, a fim de atender à demanda por meio do acionamento de um dispositivo externo acoplado por meio de um módulo E/S. O acionamento de um *airbag* veicular no momento de um acidente, ou mesmo a parada de emergência em máquinas e equipamentos industriais são exemplos de situações críticas que demandam processamento em tempo real.

3.2 Sistemas embarcados em VANT

A logística para a iniciar o processamento de imagens aéreas obtidas por VANT, por muitas vezes, demanda alto tempo. Considerando o contexto agrícola, isto pode culminar em elevado tempo de resposta e ocasionar prejuízos na lavoura. A partir de alguns trabalhos, percebe-se a necessidade de melhorias que possam garantir maior eficiência em relação ao tempo de resposta para a solução de problemas. Em (HERWITZ et al., 2004) a transmissão das imagens da câmera acoplada ao VANT ocorre por meio do barramento IEEE 1394 (*Firewire*) para uma placa-mãe AT sendo armazenadas em um disco. As imagens são recebidas pelos pesquisadores através de rádio frequência, com *downlink* de dados com velocidades superiores a 5Mb/s e o processamento ocorre posteriormente. Em (KONTITSIS; VALAVANIS; TSOURVELOUDIS, 2004), os dados dos sensores acoplados ao VANT para detecção de incêndios em florestas são enviados para uma estação terrestre para posterior análise, uma vez que os equipamentos utilizados não contavam com inteligência embarcada para interpretação dos dados. No estudo, o autor provavelmente encontrou limitações relacionadas à alta

demanda computacional exigida para o processamento automático de imagens com uso de algoritmos genéticos, dificultando a implantação da solução em sistemas embarcados existentes na época do estudo. Em (FELIZARDO et al., 2013), as imagens obtidas são enviadas para uma estação terrestre e gravadas em um disco rígido para obter maior capacidade de processamento. Cada imagem armazenada é inserida no sistema de processamento, onde é gerada uma nova imagem de saída. A estação terrestre também permite o monitoramento em tempo real do VANT através de um *link* de dados que opera na faixa de 2,4 GHz, possibilitando alterar parâmetros de bordo como velocidade, aceleração e altitude, além de verificar informações como o nível de bateria.

A partir dos trabalhos expostos, é possível perceber que as imagens capturadas durante o voo não são processadas automaticamente pelo próprio VANT. Em muitos casos são encaminhadas para uma estação base através de um *link* de dados, em outros o processamento ocorre somente quando as imagens são descarregadas em um computador, necessitando pousar o VANT para iniciar as etapas de processamento. Nestes casos, as soluções apresentadas não realizam tarefas autônomas e, conseqüentemente, o processamento não ocorre em tempo real.

Estudos realizados pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) sinalizam para o grande avanço tecnológico voltados ao setor agrícola, inclusive com uso de tecnologia para garantir características autônomas no futuro. O projeto ARARA (Aeronaves de Reconhecimento Assistidas por Rádio e Autônomas) desenvolvido em parceria com a Universidade de São Paulo, por exemplo, tem por objetivo principal a substituição de aeronaves convencionais para tirar fotografias aéreas objetivando o monitoramento de culturas e áreas de controle ambiental por aeronaves não tripuladas. O projeto é dividido em quatro fases, com aumentos dos níveis de funcionalidades, custo e complexidade até que um sistema totalmente autônomo seja capaz de realizar missões automáticas (Trindade Jr. et al., 2002).

O uso de sistemas embarcados em VANT pode proporcionar a realização de determinadas tarefas autônomas. A maioria das abordagens trata de mecanismos de controle de voo. Em (NETO et al., 2012), por exemplo, uma arquitetura embarcada modular é proposta com o objetivo principal de projetar e construir uma plataforma para desenvolvimento e pesquisas do comportamento autônomo de um VANT de pequeno porte. O autor propõe uso de um circuito principal com um processador e uma série de módulos para a realização de tare-

fas específicas, tais como: Unidade de auxílio à navegação, acelerômetros, magnetômetros, barômetros, GPS, unidade de controle do motor, dentre outros. Em (DENG; MA; ZHU, 2012) é proposto um sistema de controle de voo baseado em arquitetura reconfigurável para uso em VANT de pequeno porte. Baixo custo e confiabilidade são algumas das principais métricas estabelecidas no projeto descrito pelo autor.

Em (AMORIM et al., 2015) é apresentada uma solução para aquisição de dados de GPS, informações sensoriais e captura de imagens aéreas por um VANT. A solução utiliza um sistema embarcado popular e facilmente encontrado no mercado: A plataforma *Raspberry Pi*. A proposta abrange auxiliar um projeto para a construção de mosaicos georreferenciados a partir das imagens aéreas obtidas, além do posterior processamento para a detecção de focos de incêndio. O uso de processamento de imagens visa assegurar maior precisão por meio da fusão dos dados extraídos com as informações do GPS. O sistema embarcado *Raspberry Pi* é responsável pelas conexões necessárias de comunicação e armazenamento de dados. Em relação ao exposto pelo autor, esta dissertação apresenta como vantagem o processamento pelo próprio sistema embarcado, que poderá ser realizado logo após a aquisição da imagem, permitindo diagnósticos prévios em tempo real.

Esta dissertação propõe um sistema embarcado para o processamento de imagens durante o voo para ressaltar áreas de interesse a partir das imagens de entrada, no caso, permitir a identificação de solo exposto. Considerando o contexto agrícola, estas áreas representam falhas no plantio que se identificadas rapidamente evitam grandes prejuízos financeiros aos produtores. Aplicado ao contexto ambiental, a solução proposta pode auxiliar os especialistas no processo de mapeamento, monitoramento e análises do uso da terra por meio de demarcações e estimativas de áreas de degradação ambiental. O uso de sistemas embarcados contribui para resultados mais rápidos, evitando a necessidade de realizar o processamento de imagens posteriormente e aumento de prejuízos decorrentes das falhas encontradas no plantio.

3.3 Características dos processadores

O processador é a parte mais importante de um computador, capaz de manipular dados de uma maneira especificada por uma sequência de instruções. A unidade central de processa-

mento (CPU) realiza o controle de operações do computador e o processamento de dados. Uma subdivisão é criada quanto à tecnologia de processadores utilizada em sistemas embarcados, de acordo com as características do problema a ser resolvido, dessa forma os sistemas embarcados são divididos em três grupos: processador de propósito geral, processador de propósito único e processador de aplicação específica (STALLINGS, 2010).

Processadores de propósito geral são programados para várias aplicações, possui memória programável e garantem flexibilidade para alterações e correções no sistema. Além disso, contribuem para a redução do NRE e do tempo para conclusão do projeto, tendo em vista que basicamente, é resumido ao desenvolvimento do *software* apropriado à aplicação para qual se destina. Porém o custo por unidade pode ser alto para quantidades maiores, inviabilizando o seu uso em grande escala.

Processador de propósito único pode ser entendido como um circuito digital projetado para executar um programa específico ou uma tarefa padrão como, por exemplo, a atividade de um periférico. Possui memória não programável. Em contrapartida, verifica-se alguns benefícios como maior velocidade na execução da tarefa específica, baixo consumo e tamanho reduzido. Por outro lado pode haver um alto custo do NRE e baixa flexibilidade.

Processadores de aplicações específicas são desenvolvidos para aperfeiçoar determinadas classes de aplicações e possuem características comuns. Estes oferecem alguns benefícios como flexibilidade média, bom desempenho e tamanho reduzido.

3.3.1 Arquiteturas CISC e RISC

Computadores com arquitetura *Complex Instruction Set Computer* (CISC), como o próprio nome sugere, são computadores que utilizam um conjunto de instruções complexas. Tais sistemas são capazes de executar centenas de instruções complexas diferentes simultaneamente. Processadores clássicos de arquitetura CISC são os x86 fabricados pela *Intel Corporation*, *Motorola 68xx* e a família *Geode*, fabricados pela *National Semiconductor*.

Computadores baseados em CISC se beneficiam da técnica conhecida como microprogramação, que possui a característica de incorporar algumas funções ao processador, através de funções pré-programadas facilitando a etapa de programação. Com isso, o código desenvolvido pode se tornar mais curto, tendo em vista que partes comuns a vários programas estão inseridas no próprio processador. Isso não significa que um programa CISC será sempre me-

nor que um programa RISC correspondente, pois o número de bits ocupados na memória por um programa CISC poderá ser maior, mesmo que este apresentado em linguagem de máquina simbólica seja com menos instruções (STALLINGS, 2010).

Devido ao crescimento de dispositivos com novas funções no mercado, alguns fabricantes como a *Intel* estão investindo em solução para uso de sistemas embarcados, inclusive inovando com sistemas baseados em x86 (CISC). Esta tendência impulsiona a indústria para o surgimento de novas tecnologias cada vez mais preparadas para atender a crescente demanda de poder computacional para o surgimento de novas tarefas.

A Arquitetura *Reduced Instruction Set Computing* (RISC) são computadores com um conjunto de instruções reduzido. Significa que suportam menos instruções, porém são executadas com maior rapidez. Processadores clássicos baseados nesta arquitetura são desenvolvidos pela *ARM Ltda* que utiliza tecnologia *Advanced RISC Machine* (ARM) baseada em RISC. Atualmente, devido às necessidades de mercado, a ARM também desenvolve tecnologias para computação de alto desempenho, como por exemplo, o processador *ARMv8*, como também a sua versão *ARMv8-R* que é usado em aplicações embarcadas no setor automotivo e industrial. Outras empresas também desenvolvem processadores baseados em arquitetura ARM ou RISC, como por exemplo, o *Kinetis* desenvolvido pela *Freescale*, *MPC5xx* desenvolvido pela *IBM PowerPC*, *AVR* desenvolvido pela *Atmel* e os microcontroladores PIC fabricados pela *Microchip*.

Processadores RISC possuem um grande quantidade de registros, o que reduz a quantidade de vezes que o processador deve acessar a memória principal, podendo a variável ficar no próprio processador, não necessitando acessá-la na memória externa, o que tornaria o acesso mais lento. A maioria das operações ocorre registrador-para-registrador, com operações simples de *load* e *store* (carregar e armazenar) durante o acesso à memória (STALLINGS, 2010), simplificando o conjunto de instruções.

Geralmente, uma instrução RISC terá um ou no máximo dois ciclos para executar o código, enquanto que os processadores de arquitetura CISC, este número pode alcançar várias dezenas de ciclos para uma única instrução executada (CATSOULIS, 2005). Otimizações em código buscam reduzir a complexidade na decodificação de instruções, resultando em uma operação final mais rápida. Por meio de instruções simples e número reduzido de ciclos, a necessidade de microprogramação é eliminada. As instruções podem ser embutidas

no *hardware* para que o acesso a estas ocorra mais rapidamente. Caso isso não ocorra, tais instruções deverão ser implementadas no código, inclusive com a combinação de instruções sempre que necessário realizar uma operação mais complexa.

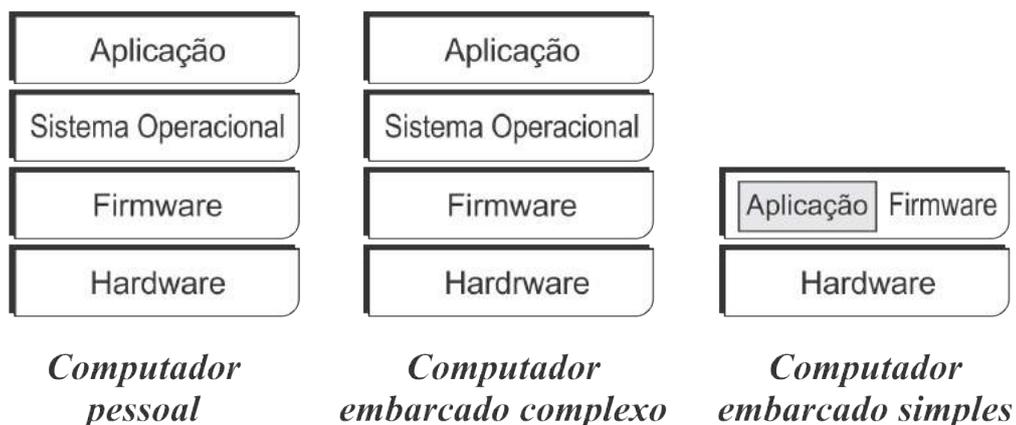
A execução de instruções simples contribui com a redução de tamanho e menor consumo de energia e garantem previsibilidade, tendo em vista que suas instruções são praticamente de tamanho fixo, ocupando um ou dois ciclos de execução por instrução. Essa característica é primordial, principalmente no projeto de sistemas embarcados críticos.

A separação em dois grupos dominantes de processadores não representam a realidade das arquiteturas desenvolvidas atualmente, de modo que é possível encontrar processadores de arquitetura CISC que implementam algumas peculiaridades da arquitetura RISC para otimizar o seu desempenho.

3.4 Software em sistemas embarcados

Apesar de não haver uma definição padronizada, em geral *software* pode ser entendido como a capacidade de realizar funções matemáticas e procedimentos que mapeiam um conjunto de dados de entrada em dados de saída (LEE, 2002). Em sistemas embarcados, o *software* controla a operação e funcionalidades do computador, possui várias camadas de modo que cada uma possa interagir com a camada imediatamente superior e imediatamente inferior, de acordo com a Figura 3.4.

Figura 3.4: Camadas de *software* entre computadores



Fonte: Adaptado de (CATSOULIS, 2005)

Em um nível mais alto, *softwares* de aplicação consistem em programas que provêm

funcionalidades ao computador, tudo abaixo disso é considerado *software* do sistema. Em um nível mais baixo, os programas são executados pelo computador na primeira vez que ele é ligado. Estes programas iniciam outros sistemas de hardware para um estado conhecido, de modo que o computador pessoal é configurado para a operação correta. Esse *software* fica armazenado na memória de forma permanente e é denominado *firmware*.

Os sistemas embarcados podem ser implementados com ou sem a utilização de um sistema operacional. Em geral, sistemas modelados com poucas tarefas não necessitam de um sistema operacional, por outro lado, sistemas que executam várias tarefas específicas geralmente utilizam um sistema operacional. A escolha de um sistema é uma das mais importantes decisões em um projeto (MOROZ; JASINSKI; PEDRONI, 2012), principalmente os que demandam processamento em tempo real. Devido às diversas vantagens oferecidas pelo sistema operacional Linux, pelo qual pode-se citar: amplo suporte a hardware, variedade de ferramentas existentes, suporte da comunidade, licenciamento de código aberto e custos (YAGHMOUR et al., 2008) a escolha de uma distribuição Linux é fundamental para implantação em sistemas embarcados.

3.5 Características dos sistemas embarcados

Características como flexibilidade, baixo custo, bom desempenho e baixo consumo de energia foram os principais fatores que subsidiaram a escolha entre os diversos sistemas embarcados disponíveis no mercado para a implantação dos algoritmos propostos. O sistema de identificação de falhas proposto neste trabalho será avaliado em três diferentes sistemas embarcados: As plataformas *DE2i-150* e *Intel Edison*, ambas de arquitetura x86 e a plataforma *Raspberry Pi 2* que utiliza arquitetura ARM.

A plataforma embarcada *DE2i-150* é fabricada pela *Altera Corporation* subsidiária da *Intel Corporation*, empresa que atua no ramo de desenvolvimento de plataformas baseadas em FPGA para aplicações acadêmicas industriais. A *DE2i-150* consiste em uma plataforma de desenvolvimento com dimensões 250x170 mm e peso 800 g. É formada por dois blocos principais: o primeiro é composto por um processador de propósito geral *Intel Atom N2600* 1,6 GHz baseado em arquitetura x86; o segundo bloco garante alta flexibilidade a projetos por meio de um módulo FPGA *Altera Cyclone IV*. A plataforma possui memória principal

DDR3 2 GB, GPU integrada, armazenamento SSD de 64 GB. Estão presentes as interfaces VGA, HDMI, *Wireless*, *Bluetooth*, áudio e Ethernet. A alimentação do *hardware* ocorre através de uma fonte de alimentação externa com tensão nominal de saída igual a 12 V e capacidade máxima de corrente 2,5 A. A plataforma é apresentada na Figura 3.5 e o diagrama em blocos disponibilizado pelo fabricante é mostrado na Figura 3.6.

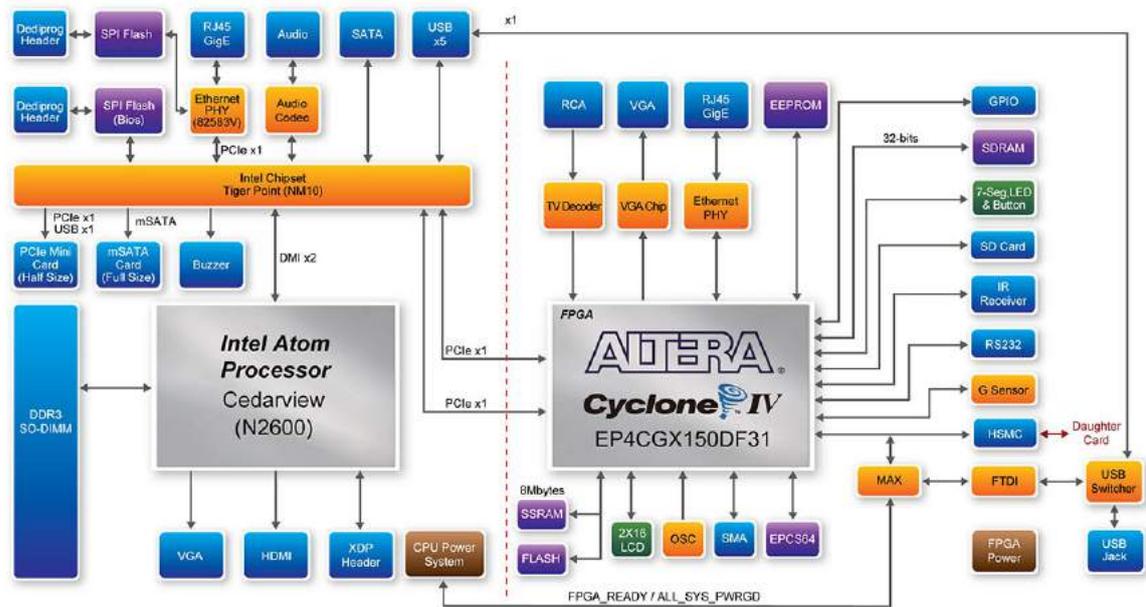
Figura 3.5: Plataforma embarcada *DE2i-150*



Fonte: Próprio autor.

A compatibilidade com diversos sistemas operacionais de interface gráfica torna a plataforma de fácil configuração. Além disso, a grande variedade de conexões físicas semelhante a um computador pessoal facilita a instalação de periféricos e, conseqüentemente, a manipulação do sistema. O sistema operacional instalado na plataforma foi o *Xubuntu*, versão 14.04 *LTS*¹. Todas as configurações necessárias foram realizadas diretamente na placa através da interface gráfica disponibilizada pelo sistema operacional. A escolha da plataforma *DE2i-150* na fase inicial do projeto se justifica pelo fato de que o pleno funcionamento do algoritmo proposto permite inferir que quaisquer outras plataformas computacionais que

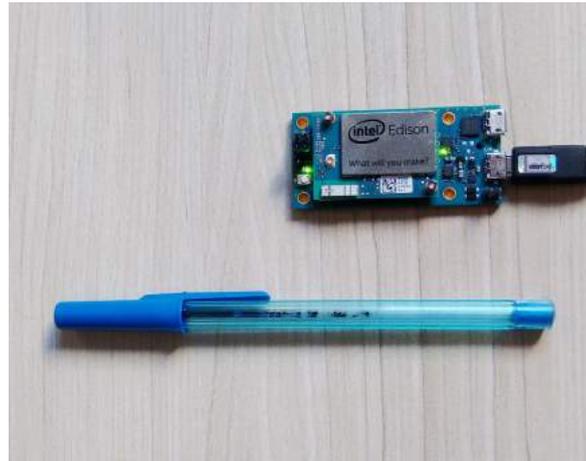
¹Versão com longo tempo de suporte

Figura 3.6: Diagrama em blocos da plataforma *DE2i-150*

Fonte: Disponível em: <http://www.terasic.com.tw>. Acesso em: 01/08/2015

possuam características similares, principalmente relacionadas ao processador e a memória principal, serão capazes de realizar o processamento de imagens, independente das características físicas da plataforma, como por exemplo, peso e tamanho.

A plataforma *Edison*, desenvolvida pela *Intel Corporation* tem como principal característica suas dimensões reduzidas, cujo módulo de processamento utilizado neste trabalho sobreposto com a interface de comunicação possui dimensões 60x28 mm e apenas 16 g de peso. Este módulo possui processador *Intel Atom Dual Core* 500 MHz baseado em arquitetura x86, memória principal DDR3 1 GB e armazenamento interno de 4 GB. A versão utilizada é a *Intel Edison Breakout Board* apresentada na Figura 3.7. Possui interfaces de comunicação *Bluetooth*, *Wireless* e *USB*. O sistema operacional instalado nesta plataforma foi o *Ubilinux* versão derivada do *Debian "Wheezy"*, baseado em Linux. O sistema instalado não possui interface gráfica, tendo em vista que a plataforma não dispõe de saídas de vídeo. Inicialmente a comunicação com a plataforma ocorreu através de outro computador como uso do *software* de emulação de terminal *putty*, por meio de um cabo *USB*. Após instalação do sistema operacional e configuração da interface de rede, a configuração do sistema pode ocorrer através da rede sem fio utilizando o protocolo *SSH*, viabilizando a manutenção ou alterações no sistema.

Figura 3.7: Plataforma *Intel Edison*

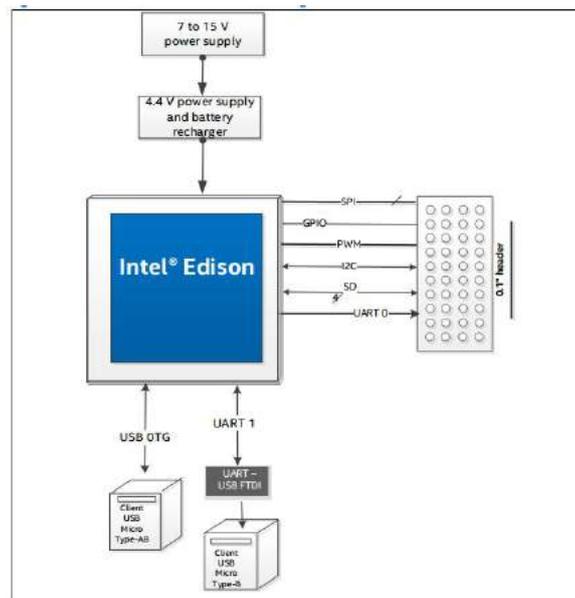
Fonte: Próprio autor.

A plataforma *Intel Edison* é de baixo consumo de energia, não consumindo normalmente mais de 200 mA, podendo apresentar picos de curta duração de até 600 mA durante a transmissão por *Wi-fi*, segundo o fabricante². A alimentação pode ser feita por um adaptador de alimentação externo, com tensões de 7 a 15 Volts de corrente contínua (DC) ou por uma bateria de lítio padrão de 4,4 V. Devido ao baixo consumo de corrente elétrica poderá também ser alimentada por uma interface USB, cuja tensão fornecida é, normalmente, 5,0 V. A comunicação ocorre por meio da porta USB *On-The-Go* (USB OTG), que traz a capacidade de dispositivos portáteis de se comunicarem com outros periféricos, ou seja, o dispositivo não funciona somente como um cliente de um periférico mestre, e sim como um dispositivo mestre recebendo outro periférico cliente, como afirma (SHIMIZU, 2012). O diagrama em blocos é exibido na Figura 3.8. A escolha da plataforma *Intel Edison* é justificada, principalmente, pelo fato de ser uma possível candidata a ser acoplada a um VANT de pequeno porte, devido ao seu tamanho e peso reduzidos. Além disso, a continuidade do uso de arquitetura x86 permite a efetiva comparação de desempenho em relação somente ao hardware utilizado, como a alteração de características do processador e memória principal. Neste caso, não há interferência motivada pela utilização de arquiteturas diferentes.

A plataforma *Raspberry Pi* desenvolvida pela fundação *Raspberry pi*³ surgiu em 2006, fruto de ideias do pesquisador Eben Upton e outros pesquisadores do laboratório de com-

²Intel Corporation., 2015. Hardware guide: Intel Edison Breakout Board. (January).

³<https://www.raspberrypi.org/> [Acesso em 01/08/2015].

Figura 3.8: Diagrama em blocos da plataforma *Intel Edison*

Fonte: Guia de hardware da plataforma Intel Edison. Disponível em: <https://software.intel.com/en-us/iot/library/edison-getting-started>. Acesso em 01/08/2015

putação da Universidade de Cambridge que desenvolveram um projeto em que todo o hardware foi inserido em uma única placa. A ideia consistiu em criar um computador pequeno e acessível para crianças com a finalidade de estimular o ensino de computação nas escolas, provocando mudanças na maneira de como crianças interagem com o computador. A plataforma *Raspberry Pi 2* modelo *B* foi lançada em fevereiro de 2015. Possui tamanho reduzido com dimensões de 85x56mm e peso 45g permitindo sua utilização em diversas aplicações do cotidiano. O modelo *Raspberry Pi 2* é uma segunda geração da *Raspberry Pi*, que já era considerada uma máquina completa, com poder de processamento razoável (UPTON; HALFACREE, 2013).

Baseado em um processador *ARMv7 Quad Core* 900 MHz de arquitetura ARM, pode executar uma grande variedade de distribuições ARM GNU/Linux. O processador utilizado é o BCM2836, um *System on Chip* (SoC) fabricado pela *Broadcom Corporation*, capaz de gerenciar a maioria dos componentes instalados no sistema, incluindo sua unidade central de processamento (CPU) e as de processamento gráfico. Possui memória principal de 1 GB, e suporte a armazenamento de dados através de um *slot* micro SD. No caso, utilizou-se um cartão micro SD classe 4 com capacidade de armazenamento de 8 GB. A Figura 3.9 apresenta a plataforma *Raspberry Pi 2* utilizada.

Figura 3.9: Plataforma *Raspberry Pi 2*

Fonte: Próprio autor.

A plataforma *Raspberry Pi 2* contempla as interfaces de comunicação USB, HDMI e Ethernet, além de conexões para acoplamentos de câmera e display. Possui também a porta *General Purpose Input/Output* (GPIO), responsável por fazer a comunicação de entrada e saída de sinais digitais através de um conjunto composto por 40 pinos, permitindo o interfaceamento com outros dispositivos e periféricos de acordo com a necessidade do projeto. O sistema operacional instalado foi o *Mate* versão 1.10, baseado em linux e com interface gráfica, tendo em vista que a plataforma possui conexão de vídeo HDMI, o que facilita a instalação e configuração do sistema realizados diretamente na plataforma. O uso da plataforma *Raspberry Pi* é justificada pelo fato de ser uma plataforma leve e possuir tamanho reduzido. Além disso, este trabalho procura avaliar o comportamento dos algoritmos propostos em sistemas embarcados de arquitetura ARM, uma vez que são facilmente encontrados e disponíveis no mercado.

Existe uma grande e crescente lista de sistemas embarcados no mercado. A Tabela 3.1 mostra exemplos e principais características de sistemas embarcados que utilizam processadores de propósito geral disponíveis no mercado. A tabela 3.2 apresenta um quadro comparativo e resumido das características dos sistemas embarcados utilizados nesta pesquisa.

Tabela 3.1: Principais plataformas embarcadas disponíveis no mercado

Plataforma	Processador	GPU	Memória Principal	Armazenamento	Tamanho (em mm)	Peso	Custo (em dólares)
Arduino Uno - R3	AVR 16MHz	-	2KB SRAM	32 KB Flash + 1 KB EEPROM	75 X 53	25g	\$25
Arndale Board	ARM Cortex-A15 1.7GHz	ARM Mali-T604 533MHz	2GB DDR3L	Sata / SD Card	195 X 140	166g	\$180
BeagleBone Black	ARM Cortex-A8 1GHz	PowerVR SGX530	512MB DDR3L	Interno 4GB eMMC	86,4 X 53,3	40g	\$50
Cubieboard	ARM Cortex A7 2.0GHz	700MHz	2GB DDR3	Interno 8GB Flash	110 X 80	220g	\$140
Intel Galileo Gen 2	x86 Quark 400MHz	-	256MB DDR3	8MB Flash / SD Card	123,8 X 72	56g	\$75
Nvidia Jetson TK1	ARM Cortex-A15 2.3GHz	Nvidia GK20A (192 cores) 950MHz	2GB DDR3L	Interno 16GB eMMC / SD Card	127 X 127	120g	\$200

Tabela 3.2: Comparação entre os sistemas embarcados utilizados

Plataforma	Processador	Memória Principal	Armazenamento	Interfaces e Portas	Sistema Operacional	Interface gráfica	Tamanho (em mm)	Peso	Custo (em dólares)
DE2i-150	x86 Atom N2600 1.6GHz	2GB DDR3	64GB SSD	VGA, HDMI, <i>Bluetooth</i> , <i>Wireless</i> , audio e Ethernet	XUbuntu 14.04 LTS	SIM	250 X 170	800g	\$700
Intel Edison	x86 Atom Dual Core 500MHz	1GB DDR3	4GB eMMC / MicroSDHC slot card	<i>Bluetooth</i> , <i>Wireless</i> e USB OTG	Ubilinux	NÃO	60 X 28	16g	\$114
Raspberry Pi 2	ARM Cortex-A7 Quad Core 900MHz	1GB LPDDR2	Micro SD	USB, HDMI, Ethernet, GPIO	Ubuntu Mate 1.10	SIM	85 X 56	45g	\$36

Capítulo 4

Pesquisas Correlatas

Neste capítulo são destacados os principais trabalhos relacionados às técnicas de processamento de imagens utilizadas no imageamento aéreo para fins agrícolas ou análises ambientais. Em todos os estudos apresentados neste capítulo, foram utilizados VANT durante a aquisição das imagens.

O imageamento adotado em (JORGE; BRANDÃO; INAMASU, 2014) é centrado no uso de sensores com base em espectroscopia de reflectância, que consiste na técnica de medição do espectro eletromagnético, ou seja, realiza medições da reflexão da radiação eletromagnética (REM) após a interação de diferentes superfícies em contato com diferentes comprimentos de onda. O espectro refletido pode cobrir a região visível, infravermelho próximo (*Near Infrared* - NIR), que compreende o intervalo de comprimento de onda $[0,7\mu\text{m} - 1,3\mu\text{m}]$ ou ainda o infravermelho de ondas curtas (*Short Wave Infrared* - SWIR), que compreende o intervalo de comprimento de onda $[1,3\mu\text{m} - 2,5\mu\text{m}]$. A formação das imagens é baseada na resposta espectral dada a partir de diferentes elementos da paisagem, como por exemplo, a resposta espectral do solo, da cultura e da água. Após a obtenção, as imagens são processadas individualmente com o objetivo de reconhecer falhas gaves. É comum o uso de técnicas que envolvem o espectro de luz visível e invisível aplicados ao sensoriamento remoto. Alguns aspectos da vegetação são verificados com o uso de sensores NIR comumente utilizadas em câmeras multiespectrais. Normalmente este tipo de câmera substitui o filtro da região azul, presente em uma câmera no espectro de luz visível (RGB), para uma gama de infravermelho. Deste modo é utilizada uma câmera NIR com as bandas NIR, R e G. O autor também utiliza imagens obtidas por câmeras hiperespectrais, que através do mesmo

princípio da espectroscopia de reflectância realiza a coleta de dados por meio de câmeras capazes de capturar centenas de bandas do espectro eletromagnético representados em um único pixel.

Com todos os recursos apresentados no trabalho de (JORGE; BRANDÃO; INAMASU, 2014) é possível realizar a identificação de falhas em plantações com alto grau de qualidade, pois com uso de múltiplas bandas a probabilidade de sucesso na segmentação é elevada. O uso de sensores hiperespectrais é capaz de reproduzir a assinatura espectral das classes e suas características de absorção associadas, aumentando ainda mais a fidelidade de informações extraídas da imagem. As imagens são obtidas usualmente no formato *RAW*, que são imagens que contém a totalidade das informações dos dados capturados, sem nenhuma etapa de compressão e por apresentarem alta resolução possuem tamanho na ordem de Gigabytes. Outra vantagem do trabalho abordado em Jorge *et al.* é a formação de mosaicos, o que permite maior precisão para um diagnóstico da área de cultivo, permitindo a geração de mapas para análises específicas como a descompactação e fertilidade do solo, auxiliando a tomada de decisões. O processamento de imagens pode ser feito em cada foto antes da formação do mosaico. Mas a formação do mosaico após a etapa de processamento pode reduzir a precisão e prejudicar o resultado final. Uma alternativa sugeria pelos autores é construir o mosaico antes do processamento para garantir a qualidade, embora demande uma capacidade de processamento muito elevada.

Vários pontos abordados em (JORGE; BRANDÃO; INAMASU, 2014) caracterizam um relevante trabalho com relação aos mais altos níveis de precisão aplicados na agricultura, porém, algumas características impedem a sua utilização em projetos de baixo custo. A construção de mosaicos é uma delas, pois é feita por *softwares* proprietários de alto custo e necessitam que cada imagem seja georreferenciada. Além disso, a etapa de processamento demanda alta capacidade computacional, principalmente se forem utilizadas as imagens em formato de mosaico, e conseqüentemente maior tempo de processamento. O uso de sensores multiespectrais e hiperespectrais para a formação das imagens também tornam o custo do projeto elevado. Ao contrário, a abordagem proposta nesta dissertação utiliza câmeras não métricas facilmente encontradas no mercado, reduzindo ainda mais os custos para a aquisição de imagens.

O sistema de processamento de imagens utilizado em (FELIZARDO *et al.*, 2013) é base-

ado em uma Rede Neural Artificial (RNA). As imagens são obtidas por uma câmera convencional acoplada a um VANT e enviadas a uma estação terrestre para futuro processamento, que ocorre a partir de um algoritmo de aprendizagem não supervisionado baseada em *Self Organizing Map* (SOM). As imagens são inseridas no sistema de processamento que gera uma nova imagem de saída, de modo que os *pixels* são agrupados de acordo com características semelhantes em duas classes dominantes, representadas pelas cores preto e branco. A Figura 4.1, retirada do artigo de Felizardo, mostra o resultado da segmentação obtida após a etapa de processamento. São realizadas duas etapas de pré-processamento, ambas manualmente. A primeira realiza uma conversão da imagem original em escala de cinza visando o uso de *software* específico para a demais etapas. A segunda faz alguns ajustes de brilho e tonalidade de cor na imagem.

Figura 4.1: Resultado do processamento baseado em RNA



Fonte: (FELIZARDO et al., 2013)

O resultado obtido pelo método descrito em Felizardo et. al é semelhante aos resultados alcançados por esta dissertação, seja a imagem de saída fornecida destacando dois grupos dominantes. Neste caso, o sistema visa à detecção de vegetação (representada pela cor branca), ruas e telhados de casas (representadas pela cor preta) visando encontrar alterações não autorizadas na terra. A principal vantagem da abordagem tratada pelo autor é o uso de algoritmos não supervisionados que eliminam a necessidade de treinamento, bem como

a utilização de câmeras não-métricas. Em contrapartida, os dois passos correspondentes a etapa de pré-processamento que visam tornar mais fácil o processo de reconhecimento são realizados manualmente.

A abordagem proposta nesta dissertação apresenta como principal vantagem, em relação ao trabalho de Felizardo *et al.*, a realização de tarefas com reduzida interferência humana e menor tempo de processamento, culminando em um tempo de resposta hábil para a solução do problema. Pois, apesar do estudo apresentado em Felizardo utilizar algoritmos não supervisionados, estes dependem de intervenção humana durante duas etapas que antecedem o uso do algoritmo baseado em RNA. Além disso, as imagens são encaminhadas e armazenadas em uma estação terrestre para o posterior processamento.

Em (MALEK et al., 2014) é apresentada uma solução atraente e de baixo custo visando à detecção automática de copa de árvores da espécie palmeira, por meio de uma câmera acoplada a um VANT. É utilizada uma câmera digital de alta qualidade com resolução máxima de 18 megapixels. A identificação ocorre por meio de técnicas de classificação baseadas em Aprendizagem de Máquina (AM). Vários atributos são utilizados na classificação, entre eles textura e contorno. O conjunto de treinamento é obtido com dados característicos de uma imagem com a presença de palmeira e outra que não contém essas características. O primeiro passo é a aquisição de uma imagem aérea do plantio e extração de suas características utilizando o algoritmo de visão computacional *Scale-Invariant Feature Transform* (SIFT), apresentado em (LOWE, 2004). Em seguida as características são analisadas através do método de treinamento conhecido como Máquina de Aprendizado Extrema (*Extreme Learning Machine* - ELM), cuja saída da classificação marcará a palmeira em vários pontos chave similares ao treinamento. Alguns problemas como a proximidade das palmeiras que geram a fusão das árvores são resolvidos utilizando morfologia matemática, denotado no artigo como perfil morfológico (*morphological profile* - MP), que visa separar grandes componentes conectados. Após a aquisição, as imagens são submetidas a uma etapa de alinhamento, como uso de *software* baseado em SIFT, cujo treinamento é composto por 10 imagens modelos que representam a copa da árvores e 15 imagens que representam outras classes de cobertura da terra presente na imagem. Com a combinação de uso dos métodos apresentados foram alcançados níveis de acurácia em torno de 96,45%.

O uso de algoritmos de aprendizagem de máquina presentes no estudo descrito em (MA-

LEK et al., 2014) permitem menor interferência humana no processo de decisão sobre a identificação de copa de árvore e garantem bons resultados quando foram adicionadas outras características, como por exemplo, a textura e contorno. Além disso, o uso de técnicas de morfologia matemática contribuem para garantir níveis de acurácia satisfatórios. Estes são pontos positivos descritos no trabalho do autor. O uso de câmeras de alta resolução contribuem também para o baixo custo do projeto. Esta dissertação apresenta como diferencial em relação ao trabalho de (MALEK et al., 2014), o uso de técnicas simples de processamento de imagens capazes de realizar o processamento em plataformas possíveis de serem acopladas aos VANT. O que não ocorre com o trabalho descrito pelo autor, em que o uso de VANT fica restrito à captação de imagens com alta qualidade e as etapas de processamento demandam alta capacidade computacional, não sendo possível embarcá-las em computadores de pequeno porte. Além disso, o uso de *softwares* proprietários em algumas etapas podem aumentar os custos do projeto.

A solução proposta em (UTO et al., 2013) utiliza sensores hiperespectrais acoplados a VANT de pequeno porte. A imagem é formada por uma câmera hiperespectral capaz de detectar 256 bandas diferentes. Um destaque para o artigo é a possibilidade de estimar com alta precisão os níveis de clorofila mesmo em diferentes condições de luminosidade, devido ao uso de sensores hiperespectrais. O artigo apresenta a montagem e os principais itens para um sistema de baixo custo composto por sensor hiperespectral, GPS, coletor de dados, *display* e fonte de energia apropriados para acoplamento no VANT MD4-1000, mostrado na seção 2.1. O artigo trata, exclusivamente, do sistema de baixo custo de captação das imagens e não traz relatos sobre as etapas de processamento, tornando-o restrito à aquisição de dados para posterior análise e/ou processamento. Apesar do uso de sensores hiperespectrais, a proposta do trabalho de Uto *et al.* é apresentada como uma solução de baixo custo. Porém, isso não corresponde à realidade dos VANT a qual se destina esta dissertação, tendo em vista que utilizou-se câmeras métricas de baixo custo facilmente encontradas no mercado. Além disso, esta dissertação apresenta técnicas que amenizam os efeitos da luminosidade do ambiente, contornando este problema com custos mais reduzidos que a estratégia adotada por (UTO et al., 2013), que utiliza sensores hiperespectrais.

Uma abordagem utilizando VANTs para detecção de incêndios em florestas é proposto em (KONTITSIS; VALAVANIS; TSOURVELOUDIS, 2004). O artigo apresenta um sistema

baseado em visão computacional para vigilância aérea capaz de interpretar e processar dados em tempo real adquiridos por uma câmera infravermelha acoplado a um VANT. Os dados dos sensores acoplados ao VANT são enviados para uma estação terrestre para posterior análise, uma vez que os equipamentos utilizados não contavam com inteligência embarcada para interpretação dos dados. Os componentes do sistema incluem etapas de pré-processamento, extração de características, classificação e tomada de decisão, este último aciona um alarme em caso da presença de fogo.

A etapa de pré-processamento consiste na redução de ruído através do uso de um filtro Gaussiano e tem por objetivo melhorar as etapas posteriores do processamento. As imagens são obtidas por meio de um sensor de infravermelho próximo (NIR) com captura em escala de cinza de 8 bits e submetidas à etapa de pré-processamento. Em seguida, as imagens são segmentadas em regiões, onde são extraídas características como o tamanho e intensidade média de cada região. Os vetores com as características são submetidos a um classificador baseado em lógica difusa que atribui a cada região um número que indica a possibilidade da região correspondente ser atribuída ao objeto de interesse. Todas as regiões com grandes chances de serem classificadas como o objeto de interesse são mantidas em um registro. Se uma determinada região persistir na grande possibilidade de ser o objeto de interesse, o alarme é disparado. (KONTITSIS; VALAVANIS; TSOURVELOUDIS, 2004) apresenta ainda estratégias para tornar a seleção de parâmetros menos dependente de interferência humana. Devido à diversidade de situações possíveis e ao conhecimento inadequado do espaço de soluções, são empregadas técnicas baseadas em algoritmo genético, alcançando taxas de acertos em torno de 90% dos casos.

A abordagem utilizada por (KONTITSIS; VALAVANIS; TSOURVELOUDIS, 2004) apresenta alguns pontos positivos importantes. Destaca-se a capacidade de realização da tarefa em tempo real. Essa característica é de grande importância, tendo em vista a aplicação preventiva de incêndios de grandes proporções em florestas. Poucas abordagens na literatura relatam a preocupação com o processamento de imagens em tempo real para aplicações ambientais ou agrícolas. Ao contrário do trabalho descrito pelo autor, esta dissertação apresenta uma abordagem, que associada ao uso de técnicas baseadas em Aprendizagem de Máquina (AM), será capaz de realizar o processamento em tempo real imediatamente após a captura da imagem durante o voo, eliminando a necessidade de fazer o *download* de dados para uma

estação terrestre com alta capacidade computacional.

Um breve resumo com as características dos principais trabalhos relacionados, assim como os apresentados nesta dissertação, é mostrado por meio do quadro comparativo disposto na Tabela 4.1.

Tabela 4.1: Quadro comparativo com os principais trabalhos relacionados

Trabalhos	Câmera não métrica	Tempo Real	Baixo Custo	Processamento Embarcado	Interf. humana reduzida
(Jorge <i>et al.</i> , 2014)	NÃO	NÃO	NÃO	NÃO	NÃO
(Felizardo <i>et al.</i> , 2013)	SIM	NÃO	SIM	NÃO	SIM
(Malek <i>et al.</i> , 2014)	SIM	NÃO	SIM	NÃO	SIM
(Uto <i>et al.</i> , 2013)	NÃO	NÃO	SIM	NÃO	NÃO
(kontitsis <i>et al.</i> , 2004)	NÃO	SIM	SIM	NÃO	SIM
Dissertação	SIM	SIM	SIM	SIM	SIM

Capítulo 5

Materiais e Métodos

Este capítulo apresenta os materiais e métodos utilizados para o desenvolvimento do sistema de identificação de falhas em plantações. A Subseção 5.1 trata da obtenção das imagens e do ambiente inicial para o processamento. A etapa de processamento de imagens utiliza duas abordagens, a primeira é descrita na Subseção 5.2 e aborda um método de segmentação baseado em *watershed*. A segunda abordagem, descrita na Subseção 5.3, trata das técnicas utilizadas para a segmentação baseada na regra do 1 - vizinho mais próximo. Como se trata de um algoritmo baseado em aprendizagem, é apresentada na Subseção 5.3.1 uma análise descritiva dos dados do conjunto de treinamento, bem como na Seção 5.3.2 os métodos utilizados para avaliação do modelo proposto.

A Seção 5.4 apresenta uma expansão do algoritmo com a implementação de duas novas funcionalidades ao sistema de processamento: estimativas de áreas de degradação e contagem de falhas. Estas soluções podem ser úteis para realizar o monitoramento ambiental em grandes áreas de vegetação. A Seção 3.5 apresenta características dos sistemas embarcados avaliados para posterior implantação do algoritmo e realização de testes. Por fim, a Seção 5.5 apresenta os métodos para avaliação de desempenho em relação a duas métricas importantes: acurácia da classificação (Seção 5.5.1) e o tempo de processamento observado durante a execução do algoritmo (Seção 5.5.2).

5.1 Obtenção de imagens e Processamento

As imagens utilizadas neste trabalho foram obtidas por câmeras não-métricas, pois são facilmente encontradas no mercado e reduzem substancialmente os custos envolvidos em projetos de imageamento aéreo. As imagens são formadas pelos canais *Red* (R), *Green* (G) e *Blue* (B). Dois grupos de imagens foram separados para avaliação e testes do algoritmo.

O primeiro grupo utiliza 20 imagens, exclusivamente do plantio de cana-de-açúcar, cedidas pela empresa *GeoAgri Tecnologia Agrícola*¹ que atua no ramo de imageamento aéreo com foco em agricultura de precisão. As imagens possuem resolução 1280 x 720 *pixels*.

O segundo grupo possui 20 imagens aéreas de uma Área de Preservação Ambiental (APA) que apresenta caracterização diversificada, com presença de mata atlântica, mangues e policulturas. Neste caso, as imagens foram obtidas por meio de trabalho de campo com sobrevoos na região. A captura das imagens foi realizada por um VANT de pequeno porte, tipo quadricóptero, modelo *DJI Phantom FC-40* (Figura 5.1) controlado remotamente nas mediações da APA da Barra do rio Mamanguape, situada no município de Rio Tinto, no estado da Paraíba. O modelo é fabricado pela empresa *DJI Innovations*, possui 800 g de peso e capacidade de carga de até 1.200 g, segundo o fabricante. O VANT é controlado remotamente através de um enlace de rádio na frequência de 2,4 GHz com alcance de até 100 m de distância. Possui uma câmera acoplada, que através de um *link* de dados transmite em tempo real as imagens para um *smartphone* do operador em solo, ou pode ser programado para armazenar automaticamente as imagens a cada período de tempo determinado. As imagens foram capturadas com resolução de 1280 x 720 *pixels*.

Parte da região visitada apresenta algum índice de degradação ambiental, visível pela presença de áreas de solo exposto. Uma das aplicações ambientais com uso de VANT é o seu uso como ferramenta auxiliar durante a validação do mapeamento de uso e cobertura da terra, conforme mostrado através de alguns resultados parciais deste trabalho abordado em (SILVA et al., 2015a). As imagens obtidas permitiram a análise com elevada precisão, principalmente em locais de difícil acesso. Além disso, as técnicas de processamento aplicadas contribuem para a análise rápida de imagens com maior eficiência, permitindo complementar diagnósticos, com precisão, em um curto período de tempo.

¹A GeoAgri foi fundada em 2009 e possui um segmento de uso de VANT compostos por câmeras e sensores para aplicações agrícolas, além de tecnologia de *software* para configuração de planos de voo.

Figura 5.1: Modelo de VANT FC-40 utilizado na captura de imagens ambientais



Fonte: Próprio autor

A decisão de utilizar dois grupos diferentes de imagens tem por objetivo avaliar o comportamento dos algoritmos e dos sistemas embarcados perante imagens que, apesar de manter um grau de semelhança, apresentam suas especificidades em diferentes aplicações. Inicialmente buscou-se atingir níveis satisfatórios de acurácia na segmentação de imagens de cana-de-açúcar e, posteriormente, foi avaliado o comportamento do sistema para imagens ambientais.

Todas as imagens utilizadas neste trabalho foram capturadas por VANT e, posteriormente, inseridas nos sistemas embarcados para avaliação e realização de testes em laboratório. O processamento das imagens foi verificado a partir dos algoritmos baseados em *watershed* e 1-vizinho mais próximo (1-NN). O algoritmo baseado em 1-NN foi verificado com diferentes quantidades de instâncias de treinamento. Os algoritmos foram inicialmente testados em um computador pessoal para avaliação dos resultados em relação à acurácia da segmentação. O computador pessoal utilizado possui a seguinte configuração: processador *Core i5-337U 1,8 GHz*, 6 GB de memória principal, HD com capacidade de 500 GB, Sistema Operacional *Ubuntu Mate 1.8.2 version*. O sistema de processamento de imagens foi desenvolvido com uso da biblioteca *OpenCV*, cuja linguagem de programação empregada foi *C++* em um ambiente Linux para todas as plataformas avaliadas e também para os dois algoritmos propostos.

5.2 Processamento baseado em Watershed

A técnica baseada em *watershed* implementada neste trabalho é dividida em seis etapas: aquisição da imagem, conversão em escala de cinza, limiarização, dilatação da imagem, transformada de distância e uma segunda etapa de limiarização. O pseudocódigo no Algoritmo 1 apresenta as etapas de processamento, em que foram detalhadas no Capítulo 2.

A partir da aquisição da imagem aérea, seja recebida diretamente através da câmera ou a partir de um banco de imagens, a segunda etapa faz a conversão da imagem original (Figura 5.2a) em escala de cinza (Figura 5.2b) através da função *cvtColor* disponível na biblioteca *OpenCV*, facilitando a etapa de limiarização. A função pode ser vista a partir Código Fonte 5.1.

Algoritmo 1 Algoritmo avaliado para processamento baseado em *Watershed*

início

```

ImagemEntrada ← /Diretorio/ImagemEntrada.jpg
ImagemSaida ← /Diretorio/ImagemSaida.jpg
Imagem1 ← ENTRADA (ImagemEntrada)
Imagem2 ← ESCALA DE CINZA (Imagem1)
Imagem3 ← LIMIARIZAÇÃO (Imagem2)
Imagem4 ← DILATAÇÃO (Imagem3)
Imagem5 ← TRANSFORMADA DE DISTÂNCIA (Imagem4)
Imagem6 ← LIMIARIZAÇÃO (Imagem5)
SALVAR_ARQUIVO (ImagemSaida, Imagem6)

```

fim

Código Fonte 5.1: Trecho para conversão da imagem em escala de cinza

```

1 cv::cvtColor (IMGs.Origem , IMGs.Cinza , CV_BGR2GRAY); //transforma a imagem em
    escala de cinza usando CV_BGR2GRAY);

```

Após a imagem ser convertida em escala de cinza, a primeira técnica de limiarização (T_1) global é aplicada. Devido a sua simplicidade, esta etapa não requer alto poder de processamento computacional. Para a imagem apresentada na Figura 5.2b, por exemplo, foi utilizado o limiar $T_1 = 200$, configurado através da função *threshold* disponível no *openCV*. Isso significa que *pixels* com valor de nível de cinza inferior a 200 foram definidos com valor igual a zero; caso contrário, foram definidos com valores igual a 255. A escolha do valor de limiar T_1 ocorre de forma visual, de forma que valores são testados inicialmente até que a segmentação corresponda à níveis aceitáveis de semelhança com as imagens originais,

Figura 5.2: Imagens após etapas iniciais do algoritmo *Watershed*

(a) Imagem original

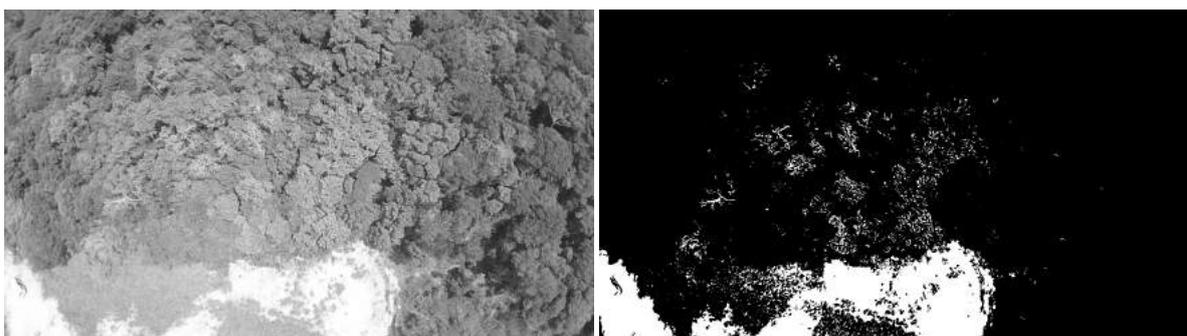
(b) Imagem em escala de cinza

Fonte: Próprio autor.

representando satisfatoriamente as áreas de interesse.

Devido à grande variedade de vegetação encontrada nas imagens obtidas pelo VANT, os valores de limiar $T1$ sofreram adaptações para se adequar a cada subgrupo analisado, pois as imagens foram obtidas a partir de diferentes horários do dia e sob diversas condições de luminosidade, necessitando ajustar os valores de limiar para o correto processamento das imagens. O resultado da imagem após a técnica de limiarização pode ser comparado com a imagem em escala de cinza na Figura 5.3.

Figura 5.3: Comparação entre imagem em escala de cinza e primeira etapa de limiarização



(a) Imagem em escala de cinza

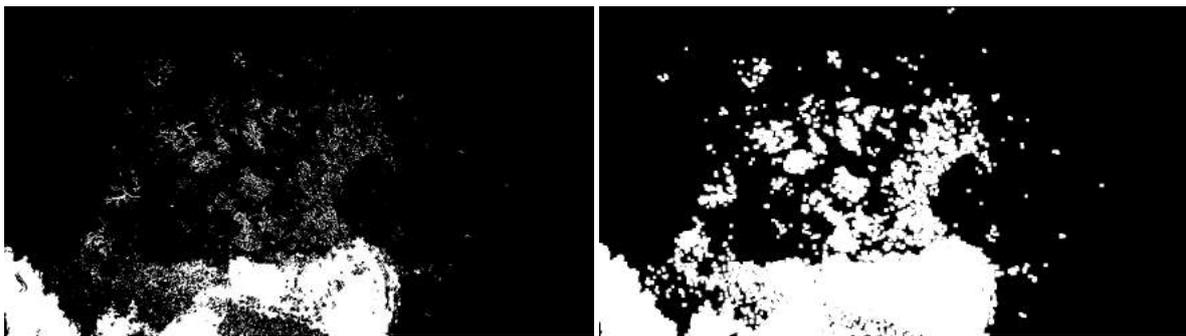
(b) Imagem após primeira limiarização

Fonte: Próprio autor.

Após a etapa de limiarização, verifica-se um grande volume de ruído na imagem, tendo em vista que o processamento ocorre no nível de pixel. A etapa seguinte tem por objetivo unir *pixels* desconexos de mesma intensidade (0 ou 255) em áreas próximas. Isto ocorre através

da função *Dilate* disponível no *openCV*. A função utiliza parâmetro igual a três iterações que representa a quantidade de vezes que a dilatação é aplicada. O uso de três iterações foi escolhido por oferecer um melhor resultado durante as etapas seguintes. O resultado da dilatação contribui com as próximas etapas para o tratamento do ruído residual gerado na etapa de limiarização. O resultado após etapa de dilatação de *pixels* sobre a imagem que sofreu a primeira limiarização pode ser comparado entre as Figuras 5.4a e 5.4b.

Figura 5.4: Comparação entre imagem após a etapa de dilatação



(a) Imagem após primeira limiarização

(b) Imagem após dilatação de *pixels*

Fonte: Próprio autor.

A quarta etapa utiliza a função *transformDistance* na imagem gerada após o processo anterior que permite, a partir de uma matriz 3x3, a distribuição de diversos pontos da imagem de acordo com o cálculo da distância do centro da matriz até a sua borda, modificando a imagem de acordo com a matriz calculada. Esse processo resulta na imagem em gradiente apresentada na Figura 5.5a. Após essa etapa os valores da matriz são normalizados e devem agora ser considerados pertencentes ao intervalo [0-1].

A nova imagem é então submetida a uma segunda etapa de limiarização com o objetivo de filtrar os níveis de gradiente gerados na etapa anterior, ressaltando somente a região de interesse, conforme mostrado na Figura 5.5b. Considerando o exemplo da imagem, foi definido na segunda etapa de limiarização o valor de limiar $T = 0,35$, escolhido visualmente de forma que a imagem final processada corresponda às áreas de solo exposto. Ao final desta etapa, a tarefa de segmentação se completa e proporciona subsídios para interpretação humana ou aplicação de outros métodos computacionais.

Os parâmetros de limiar $T1$ e $T2$ devem ser configurados para a análise de cada tipo de

Figura 5.5: Resultados após a etapa de transformada de distância e segunda limiarização



(a) Aplicação da transformada de distância

(b) Imagem após segunda etapa de limiarização

Fonte: Próprio autor.

plantação devido às características intrínsecas pertencentes a cada grupo de imagens, além de outros fatores como a luminosidade do ambiente.

O algoritmo *watershed* resulta tradicionalmente em uma imagem em gradiente conforme a Figura 5.5a acrescida de linhas conhecidas como barreiras de *watershed*. Como o objetivo deste trabalho é a identificação de solo exposto, ao invés da obtenção dessas barreiras, optou-se por buscar os limites de contorno que, considerando uma interpretação topográfica, representariam a base das barragens obtidas pelo algoritmo de segmentação, que pode ser vista na Figura 5.5b.

5.3 Processamento baseado na técnica do 1 - Vizinho mais próximo

A etapa de processamento de imagens baseada na técnica do 1 - vizinho mais próximo utiliza os três canais de imagem capturados pela câmera colorida, que correspondem aos níveis de vermelho (*Red*), verde (*Green*) e azul (*Blue*) de cada pixel. Dessa forma, a classificação ocorre pixel-a-pixel, de acordo com distância euclidiana descrita na Subseção 2.4.2 do Capítulo 2.

A partir das amostras de uma imagem, foi extraído um conjunto de treinamento que contenha dados sobre os níveis RGB representativos de vegetação e solo exposto, composto inicialmente por 427 instâncias. Cada instância representa as informações RGB contidas em

um único pixel e a escolha destes foi realizada manualmente para avaliar o comportamento da classificação com esta quantidade de dados presentes no conjunto de treinamento. Buscou-se utilizar a maior variedade de níveis de cor durante a escolha do conjunto de treinamento para representar as classes. Quatro atributos numéricos são utilizados, referentes aos níveis de *Red* (atributo 0), *Green* (atributo 1) e *Blue* (atributo 2), que variam entre 0 a 255, e o atributo denominado Saída S (atributo 3), cuja informação é binária e trata da classe do pixel, com valor 0 (zero) para representar vegetação e 1 para representar solo exposto. A seguir foi separado um subgrupo composto por 128 instâncias de treinamento, equivalente a 30% do primeiro, para avaliar o comportamento e desempenho do algoritmo com este novo conjunto de treinamento. Esta nova quantidade de dados presentes no conjunto de treinamento foi escolhida para avaliar o comportamento da classificação com uma expressiva redução do conjunto de dados, em relação à acurácia e desempenho do algoritmo.

Com o objetivo de reduzir a influência da luminosidade presente em algumas técnicas de segmentação de imagens, foi realizada a transformação do espaço de cores RGB para o espaço *Hue, Saturation, Intensity* (HSI). Desta forma, os atributos R, G e B foram submetidos às equações descritas na Subseção 2.4.1 do Capítulo 2 e um novo conjunto de dados foi gerado. Os quatro atributos se referem aos níveis de *Hue* (H), *Saturation* (S), *Intensity* (I) e a Classe (S). A função de conversão do espaço de cores foi implementada para facilitar a manipulação de novos conjuntos de dados de treinamento. O Trecho do código cuja função é converter dados entre o espaço de cores RGB e HSI é mostrado no Código Fonte 5.2.

Código Fonte 5.2: Trecho do código de conversão do espaço de cores RGB para HSI

```
1 using namespace std;
2 using namespace cv;
3     static double rad = 57.2958;
4     RGBtoHSI::RGBtoHSI() {};
5     vector<double> RGBtoHSI::convert(std::vector<int> rgb){
6         double I = (rgb[0] + rgb[1] + rgb[2]) / 3.0; // correto
7         double minimum = rgb[0];
8         if (rgb[1] < minimum){
9             minimum = rgb[1];
10        }
11        if (rgb[2] < minimum){
12            minimum = rgb[2];
13        }
14        double H, S = 0;
15        if (I > 0){
```

```

16         S = 1 - minimum / I;
17     }
18     if (rgb[1] >= rgb[2]){H = 57.2958 * acos(((rgb[0] - rgb[1] + rgb[0] - rgb
        [2]) / 2.0) / sqrt(pow(rgb[0] - rgb[1], 2) + (rgb[0] - rgb[2])*(rgb[1]
        - rgb[2])));}
19     else {H = 360 - 57.2958 * acos(((rgb[0] - rgb[1] + rgb[0] - rgb[2]) / 2.0) /
        sqrt(pow(rgb[0] - rgb[1], 2) + (rgb[0] - rgb[2])*(rgb[1] - rgb[2])));}
20     }
21     std::vector<double> hsi(3);
22     hsi[0] = H;
23     hsi[1] = S;
24     hsi[2] = I;
25     return hsi;
26 }

```

Após esta etapa, a informação de luminosidade (I) é descartada e o algoritmo K-NN utilizará apenas as informações numéricas dos atributos *Hue* (atributo 0), *Saturation* (atributo 1) e a Classe S (atributo 2) presente no conjunto de treinamento para a classificação de *pixels* em novas imagens. O pseudocódigo para utilização da técnica do 1-vizinho mais próximo utilizado neste trabalho é mostrado através do Algoritmo 2.

Algoritmo 2 Método para verificar a classe mais próxima

```

início
    METODO CLASSE KNN (atributos)
    início para
        (i=0,i<txt_hsi;i++)
        distancia ← raiz ( potencia(H-atributo [h],2) + potencia(S-atributo[s],2) +
        potencia(I-atributo[i],2))
        se i == 0 então
            distancia1 ← distancia
            instancia ← 0
        senão
            se distancia < distancia1 então
                distancia1 ← distancia
                instancia ← i
        fim
    fim para
        retornar instancia
fim

```

Nesta etapa, o classificador K-NN calcula as distâncias de cada pixel da imagem para cada elemento do conjunto de treinamento. A classe da menor distância euclidiana encontrada será atribuída à instância desconhecida. O pseudocódigo no Algoritmo 3 apresenta

as etapas para classificar o novo pixel de modo que a imagem de saída seja formada. Um resumo dos procedimentos adotados para obtenção dos dados de treinamento e avaliação do modelo é mostrado por meio do diagrama em blocos da Figura 5.6

Algoritmo 3 Método para classificar novas instâncias

```

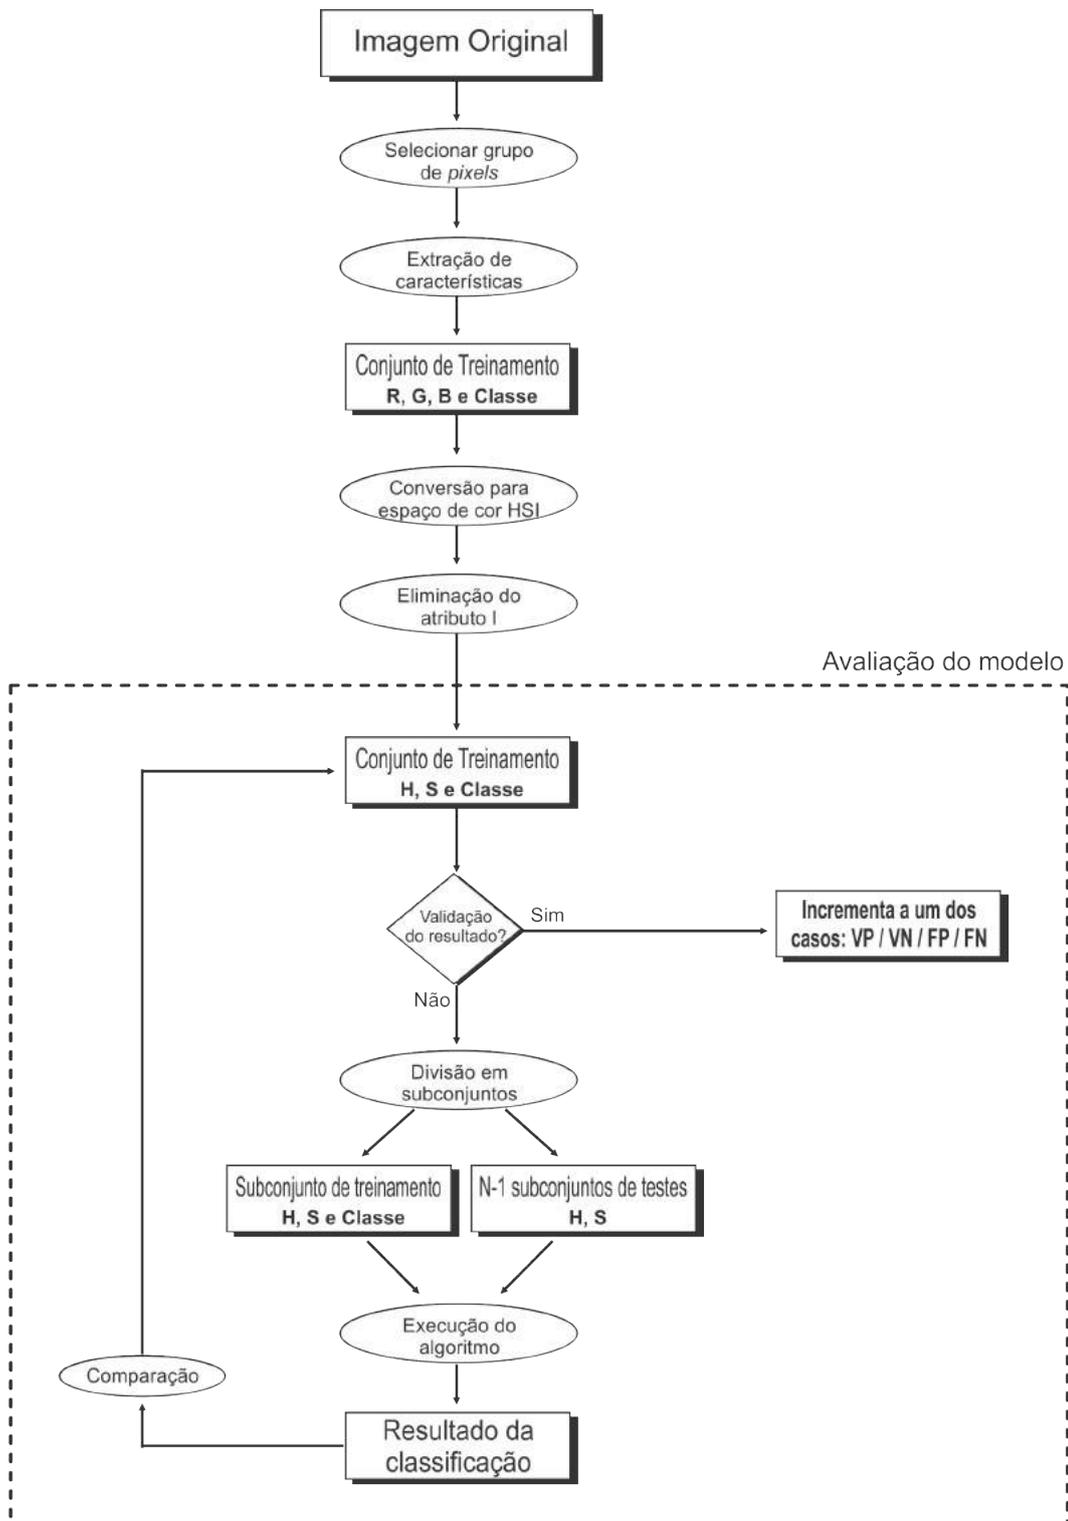
início
  METODO CLASSIFICAR (txt_rgb, txt_hsi, img)
  início para
    (x=0,x<quantidade_de_linhas;x++)
    início para
      (y=0, y<quantidade_de_colunas;x++)
      R ← img(x,y).r
      G ← img(x,y).g
      B ← img(x,y).b
      instancia ← RGBparaHSI (R,G,B)
      resultado ← KNN.KNN (instance)
      se resultado == 0 então
        img(x,y).r ← 255
        img(x,y).g ← 255
        img(x,y).b ← 255
      senão
        img(x,y).r ← 0
        img(x,y).g ← 0
        img(x,y).b ← 0
      fim
    fim para
  fim para
  retornar img
fim

```

5.3.1 Inferência estatística aplicada ao conjunto de dados

A partir dos dados de treinamento é possível analisar, separadamente, o comportamento da intensidade dos níveis de cinza dos canais vermelho (R), verde (G) e azul (B) para as classes vegetação e solo. Dados estatísticos como a média \bar{x} , desvio padrão amostral S e coeficiente de variação (CV) são obtidos. Considerando um conjunto de n amostras de valores numéricos $x^j = \{x_1, x_2, x_3, \dots, x_n\}$, em que cada x_i representa um valor, a média \bar{x} é obtida a partir da Equação 5.1. O desvio padrão é obtido a partir da Equação 5.2. O CV representa a variabilidade dos dados em relação à média, de forma que quanto maior o CV mais homogêneo é

Figura 5.6: Diagrama em blocos da obtenção de dados de treinamento e avaliação do modelo



Fonte: Próprio autor.

o conjunto de dados. Segundo (PIMENTEL, 2000), os coeficientes de variação são classificados em quatro níveis: baixo, médio, alto e muito alto. São considerados baixos quando CV é inferior a 10%, enquanto que o intervalo de 10% a 20% são considerados médios, de 20% a 30% são julgados altos e acima dos 30% são classificados como muito altos, indicando alta variação dos dados. O coeficiente de variação é obtido a partir da Equação 5.3.

$$\bar{x}^j = \frac{1}{n} \sum_{i=1}^n x_i \quad (5.1)$$

$$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}^j)^2} \quad (5.2)$$

$$CV = \frac{S}{\bar{x}} \quad (5.3)$$

O grupo composto por 427 amostras possui 171 *pixels* representativos da classe vegetação (40% do conjunto de amostras) e 256 representam a classe solo (60% do conjunto de amostras), cujas informações estatísticas como a média, mediana e desvio padrão dos valores de intensidade de cinza referente aos níveis de R, G e B estão dispostas na Tabela 5.1

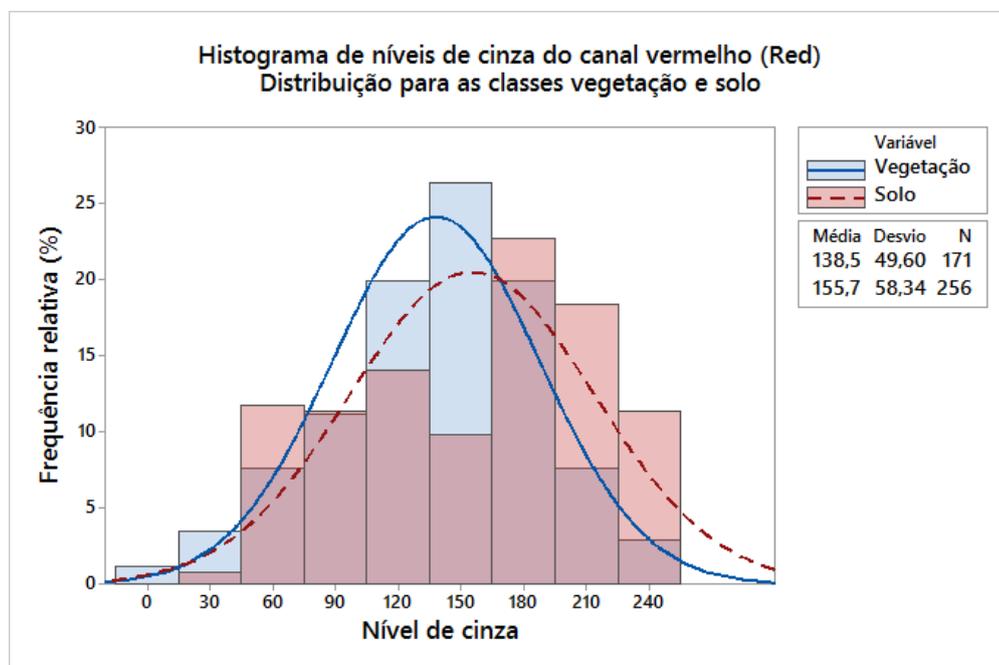
Tabela 5.1: Estatísticas sobre os canais RGB com 427 amostras de treinamento

	Vegetação ($n = 171$)			Solo ($n = 256$)		
	Média (\bar{x})	Desvio (S)	CV	Média (\bar{x})	Desvio (S)	CV
Canal R	138,5	49,60	35,8%	155,7	58,34	37,5%
Canal G	153,9	56,21	36,5%	131,6	53,87	40,9%
Canal B	103,8	43,70	42,1%	98,02	43,75	44,6%

O comportamento do canal vermelho (R) apresenta menor variação de níveis de cinza para a classe vegetação em comparação com a classe solo, cuja concentração ocorre entre os níveis do intervalo [105-195] em aproximadamente 68% das amostras, conforme podemos inferir através do histograma apresentado na Figura 5.7. Enquanto que *pixels* representativos da classe solo carregam informações deste canal com níveis de cinza mais altos, principalmente acima do nível 165, mostrando maior incidência da cor vermelha na classificação de solo. O canal verde (G) para a classe vegetação apresenta níveis de cinza elevados na grande maioria das amostras, onde aproximadamente 70% apresentam valores superiores a 135. Em contrapartida, os níveis de verde para a classe solo apresentam, na maioria das vezes, valores

inferiores ao nível 165, conforme histograma mostrado na Figura 5.8. O canal *B* apresenta uniformidade em relação as classes solo e vegetação, com predominância de valores de nível de cinza abaixo de 135 em ambas classes, conforme pode-se inferir do histograma mostrado na Figura 5.9 e também da menor diferença verificada entre os valores de CV encontrados. Observa-se, a partir das informações dadas, que para a classificação com 427 amostras de treinamento, as informações do canal *R* e *G* são essenciais e influenciam diretamente na determinação da classe, de modo que *pixels* com valores de *R* maiores que *G* tendem a ser classificados como solo e, conseqüentemente, *pixels* com valores de *G* superiores a *R* tendem a ser classificados como vegetação.

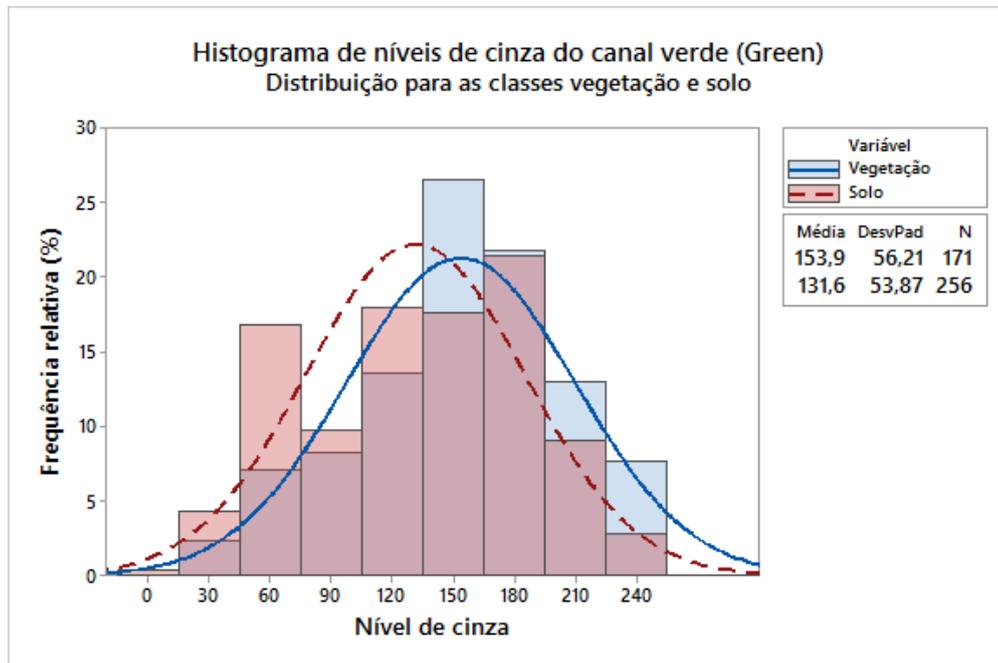
Figura 5.7: Histograma com níveis de cinza do canal R com 427 amostras



Fonte: Próprio autor.

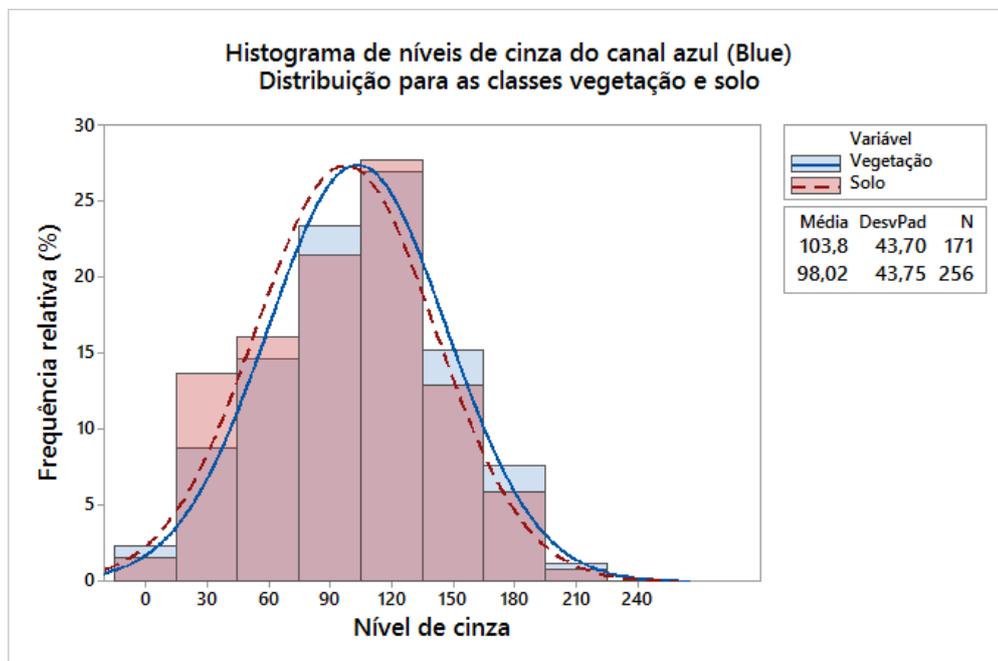
A redução de até 70% do tamanho do grupo originalmente extraído busca avaliar e comparar os resultados obtidos em relação ao desempenho do sistema. A utilização de um subgrupo pode balancear a eficiência computacional e a acurácia, de modo que estes parâmetros possam ser equilibrados e garantam boa eficiência com menor custo computacional. A partir do conjunto original, foi formado o subgrupo composto por 128 amostras, dos quais 57 são *pixels* representativos da classe vegetação (aproximadamente, 44% das amostras) e 71 da classe solo (aproximadamente, 56% das amostras). Algumas estatísticas sobre os canais

Figura 5.8: Histograma com níveis de cinza do canal G com 427 amostras



Fonte: Próprio autor.

Figura 5.9: Histograma com níveis de cinza do canal B com 427 amostras



Fonte: Próprio autor.

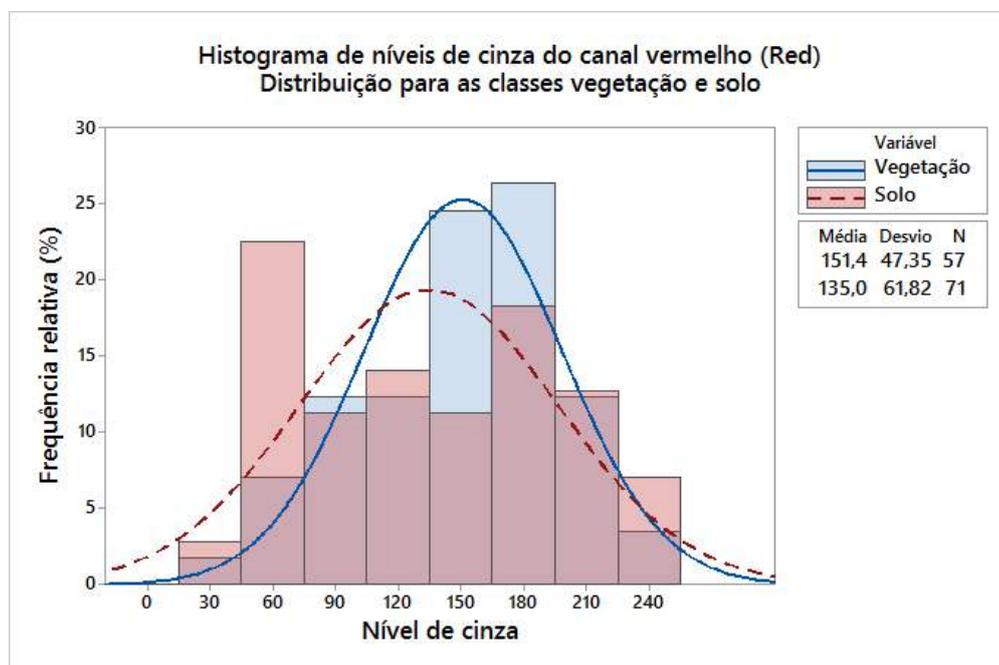
RGB do grupo composto por 128 amostras são apresentadas na Tabela 5.2

Tabela 5.2: Estatísticas sobre os canais RGB com 128 amostras de treinamento

	Vegetação ($n = 57$)			Solo ($n = 71$)		
	Média (\bar{x})	Desvio (S)	CV	Média (\bar{x})	Desvio (S)	CV
Canal R	151,3	47,3	31,3%	135	61,8	45,8%
Canal G	165,0	49,3	29,8%	120,6	58,4	48,4%
Canal B	115,3	43,1	37,3%	91,3	44,8	49%

O comportamento do canal vermelho (*Red*) para a classe vegetação apresenta menor variação de níveis de cinza em relação ao grupo anteriormente avaliado, com um CV igual a 31,3% e predominância nos níveis compreendidos entre o intervalo [135-195]. Apesar dos *pixels* representativos da classe solo apresentar maior variação que o conjunto anteriormente avaliado, a maioria dos valores superiores ao nível de cinza 195 estão relacionados a esta classe, conforme mostra o histograma de níveis de cinza do canal vermelho na Figura 5.10 para o conjunto de 128 amostras.

Figura 5.10: Histograma com níveis de cinza do canal R com 128 amostras

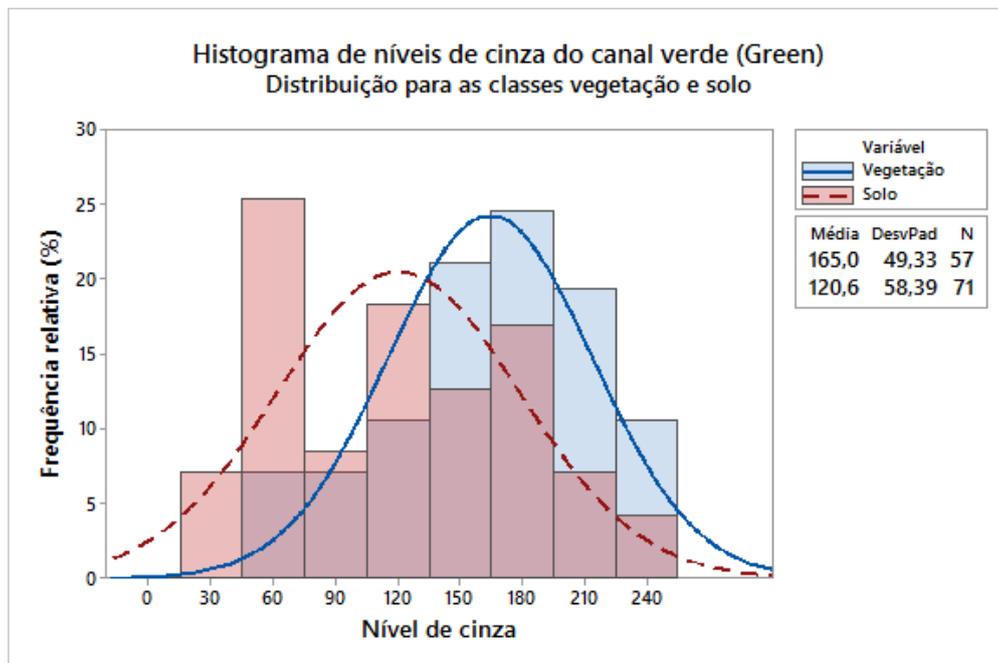


Fonte: Próprio autor.

O canal verde (*Green*) para a classe vegetação a partir do subgrupo criado apresenta menor variação de níveis de cinza, e mantém o mesmo padrão do grupo originalmente criado,

com, aproximadamente, 70% dos valores de nível de cinza superiores a 135. Da mesma forma, os níveis de verde para a classe solo apresentam em sua maioria baixos índices de nível de cinza, conforme mostrado na Figura 5.11.

Figura 5.11: Histograma com níveis de cinza do canal G com 128 amostras



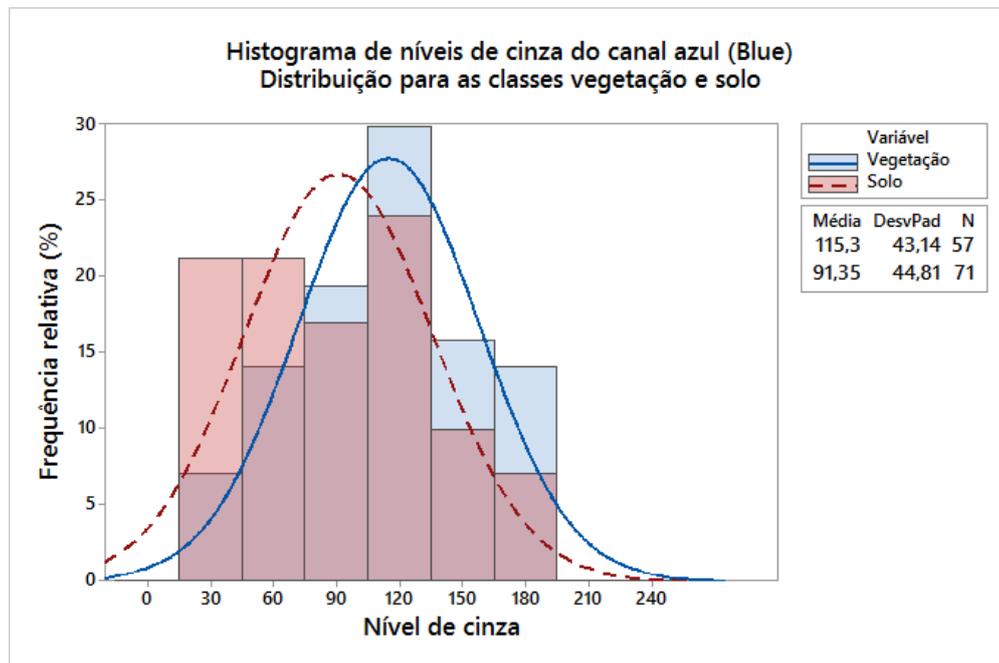
Fonte: Próprio autor.

O canal azul (*Blue*) apresenta leve variação da uniformidade em relação às classes solo e vegetação em comparação com o conjunto original de dados, com CV similares, porém ainda com grande predominância de valores de nível de cinza abaixo de 135, principalmente para a classe solo, conforme mostrado na Figura 5.12

Os conjuntos de dados de treinamento apresentados mostram-se equivalentes e, apesar da redução do número de amostras, o grupo composto por 128 apresentam dados mais balanceados em relação ao grupo com 427 amostras. Isso é justificado pelo fato do grupo inicial possuir 40% e 60% dos *pixels* representativos das classes vegetação e solo, respectivamente. Enquanto que o grupo composto por 128 amostras possui 44% dos *pixels* selecionados para representar a classe vegetação e 66% dos *pixels* são representativos da classe solo.

É possível inferir que durante a seleção dos *pixels* houve maior diversidade na escolha daqueles que representam a classe solo. Este fato é notável a partir dos elevados índices de CV encontrados para esta classe, independente da quantidade de amostras utilizadas. A

Figura 5.12: Histograma com níveis de cinza do canal B com 128 amostras



Fonte: Próprio autor.

diversidade do conjunto de treinamento é fundamental para garantir que o classificador funcione adequadamente para as mais variadas situações, evitando fenômenos como *overfitting* e *underfitting*. Segundo (LORENA; CARVALHO, 2007), o *overfitting* ocorre quando o modelo se especializa nos dados utilizados em seu treinamento, apresentando alto erro quando confrontado com novos dados. Enquanto que o *underfitting* ocorre quando os exemplos de treinamento são pouco representativos (REZENDE, 2003).

5.3.2 Avaliação do modelo de dados

A avaliação da eficiência do modelo do conjunto de dados é obtida através do *software* WEKA², versão 3.6.12, desenvolvido pela universidade de *Waikato* (WEKA, 2015). Após a inserção do conjunto de dados no programa, foi selecionado o classificador *IBK* com parâmetro $k = 1$, que corresponde a uma versão do algoritmo de classificação baseado em 1-vizinho mais próximo e usa a distância Euclidiana com todos os atributos normalizados

²*Waikato Environment for Knowledge Analysis (WEKA)* é um software desenvolvido em Java, gratuito e de código aberto, capaz de minerar os próprios dados a partir de um conjunto de entrada transformando informações úteis para encontrar tendências e padrões.

entre o intervalo [0-1] (DRIESSENS et al., 2006). A validação foi feita a partir da técnica *r-fold Cross Validation* que pode ser aplicada em diversos tipos de problemas (ZHANG, 1993). A técnica consiste em particionar o conjunto de dados em N subconjuntos de tamanhos iguais ou aproximados, em que cada um é retido com dados de validação para ser testada com todos os outros $N - 1$ subconjuntos de dados criados. Esse processo é repetido N vezes, utilizando em cada ciclo uma partição diferente para teste (FACELI et al., 2011). Nesta etapa foi utilizado 10 subconjuntos de dados ($N = 10$). A eficiência do conjunto de dados é medida a partir da matriz de confusão e da acurácia do modelo criado.

Considerando um problema com duas classes "a" e "b", sendo uma classe positiva (+) e a outra negativa (−), é possível construir a matriz de confusão ilustrada na Tabela 5.3 em que:

- VP representa a quantidade de verdadeiros positivos, ou seja, dados rotulados positivos que foram classificados corretamente.
- VN representa a quantidade de verdadeiros negativos, ou seja, dados rotulados negativos que foram classificados corretamente.
- FP representa a quantidade de falsos positivos, ou seja, dados cuja classe verdadeira é negativa, porém classificada incorretamente como positiva.
- FN representa a quantidade de falsos negativos, ou seja, dados cuja classe verdadeira é positiva, porém classificada incorretamente como negativa.

Tabela 5.3: Matriz de confusão para o problema com duas classes

Classificação →		+	−
Classe <i>a</i> verdadeira	+	VP	FN
Classe <i>b</i> verdadeira	−	FP	VN

A acurácia representa a taxa de acerto do modelo, sendo obtida pela Equação 5.4, em que n representa o número de amostras do conjunto de dados. Os parâmetros de entrada utilizados no *software* de avaliação do modelo são as informações do canal *Hue* (H) e *Saturation* (S).

$$ac(\hat{f}) = \frac{VP + VN}{n} \quad (5.4)$$

5.4 Aplicações Ambientais

As imagens ambientais foram submetidas às técnicas de processamento propostas neste trabalho. No total, 20 imagens ambientais foram selecionadas para testes e avaliação de resultados. Considerando o contexto da aplicação, duas novas funcionalidades são criadas. A primeira tem por objetivo realizar uma estimativa do total de áreas degradadas, ou seja, áreas que representam solo exposto na vegetação. Estas informações são úteis para identificar e gerar dados de percentagem sobre os níveis de degradação ambiental e auxiliam o monitoramento de áreas de vegetação natural e/ou monocultura e policultura. A segunda funcionalidade se encarrega de estimar a quantidade e o ponto central das falhas. Esta última pode ser útil, por exemplo, para analisar a melhor trajetória entre os pontos que podem ser visitados por um VANT em altitudes mais baixas, visando a aquisição de novas imagens com maior resolução espacial. A estimativa de áreas de solo exposto e ponto central de cada falha são aplicadas após todas as etapas de segmentação de imagens, independentemente do método utilizado.

O cálculo total de áreas degradadas em uma imagem segmentada é feito a partir da contagem de *pixels* que representam solo e vegetação desta imagem. O algoritmo analisa cada coordenada (x, y) da imagem e verifica qual valor binário (0 ou 255) do nível de cinza pertence à respectiva coordenada ou pixel. A partir da contagem e frequência de ocorrência desses valores é possível, a partir de uma relação simples, calcular os percentuais que representam solo e vegetação que são representados nas imagens através das cores preto e branco, respectivamente. O pseudocódigo mostrado através de Algoritmo 4 apresenta a função para estimar o total de áreas de solo exposto presente em uma imagem.

A imagem segmentada mostrada na Figura 5.13a, por exemplo, é interpretada pelo sistema como uma matriz composta por 921.600 *pixels* (considerando a imagem de resolução 1280x720), dos quais 53.062 referem-se ao valor 255, permitindo inferir que aproximadamente 5,76% da imagem representam áreas de solo exposto. Aproveitando o exemplo, a Figura 5.13b traz uma representação das áreas de solo exposto encontradas A1, A2, A3, e A4 sob os eixos x e y da imagem, como também a simulação do posicionamento destas áreas na imagem. As coordenadas que representam o ponto central das quatro áreas de solo exposto encontradas podem ser vistas na Tabela 5.4.

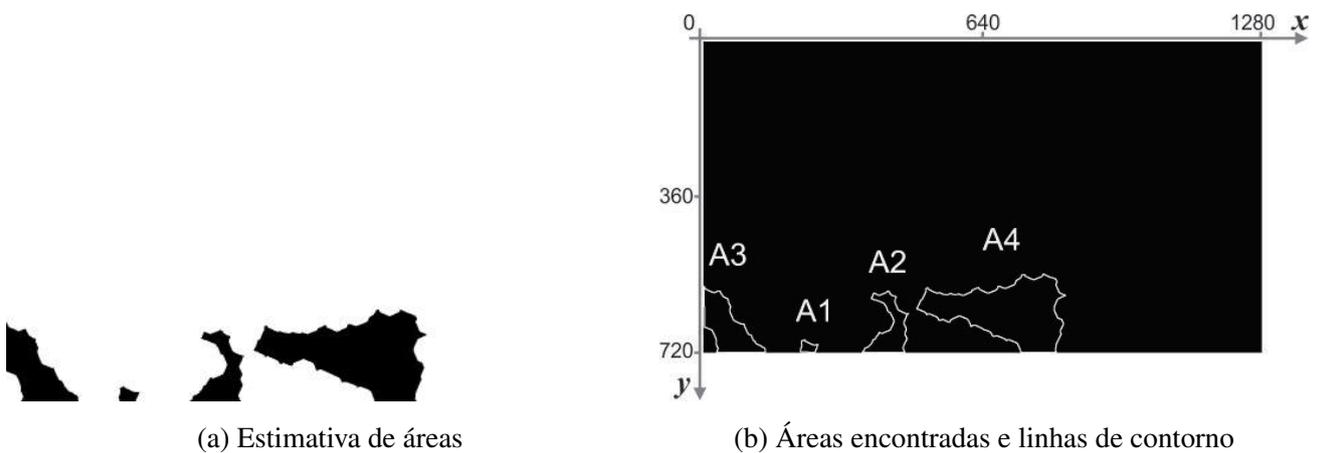
Algoritmo 4 Função estimativa de áreas de solo exposto

```

início
  Percentual_Preto: Float
  Entrada: area ← CALCULAR ÁREA (ImagemOrigem)
  início para
    (Y=0; Y < ImagemOrigem.Linha; Y++)
    início para
      (X=0; X < ImagemOrigem.Coluna; X++)
      se ImagemOrigem(Y,X)=0 então
        | SomaPreto++
      senão
        | SomaBranco++
      fim
    fim para
  fim para
  Saída: Percentual_Preto ← SomaPreto*100/(SomaBranco+SomaPreto)
fim

```

Figura 5.13: Imagem segmentada (a) e representação de áreas encontradas (b)



Fonte: Próprio autor.

Tabela 5.4: Coordenadas centrais $P(x,y)$ estimadas para áreas de falhas

	Áreas com falhas identificadas			
Ponto Central:	Área 1	Área 2	Área 3	Área 4
$P(x,y)$	P(239, 702)	P(422, 643)	P(66, 652)	P(665, 609)1

A estimativa do ponto central das falhas encontradas pelo algoritmo utiliza informações do contorno da imagem segmentada extraída a partir da função do *findcontours*, disponível na *OpenCV*, que fornece todas as coordenadas de *pixels* da região de contorno da imagem. Diante dessas informações, calcula-se a média das coordenadas x e y a fim de estimar a posição central de áreas, viabilizando também a contagem de falhas encontradas pelo algoritmo. O pseudocódigo mostrado por meio do Algoritmo 5 apresenta a função que identifica as regiões de contorno para estimar o ponto central das falhas identificadas em uma imagem.

Algoritmo 5 Função contorno para estimativa de ponto central

```

início
  Entrada: Contorno  $\leftarrow$  BUSCAR-CONTORNO (ImagemOrigem)
  início para
    (k = 0 ; k < Contorno.Tamanho; k++)
    ImagemContorno  $\leftarrow$  Desenharm_contorno(k);
  fim para
  início para
    Para (x=0; x < Contorno.Tamanho; x++)
      início para
        Para (y=0; y < Contorno.Tamanho; y++)
          SomaX  $\leftarrow$  Contorno(XY).x
          SomaY  $\leftarrow$  Contorno(XY).y
      fim para
    fim para
  Saída: Ponto central: Média X;Y  $\leftarrow$  SomaX/x; SomaY/y
fim

```

5.5 Avaliações de desempenho

A avaliação de desempenho dos algoritmos de processamento de imagens propostos é subdividida em duas partes: A primeira abordagem está relacionada à acurácia das imagens processadas em relação às imagem originais de entrada. A segunda abordagem está relacionada ao tempo de processamento demandados a partir dos sistemas embarcadas e um

computador pessoal.

5.5.1 Avaliação em termos de acurácia

As imagens são analisadas a partir da comparação de resultados entre a segmentação realizada pela técnica baseada em *watershed* e o melhor resultado obtido através do processamento a partir do algoritmo baseado no 1-vizinho mais próximo (1-NN). Considerando que este último é avaliado em diferentes quantidade de amostras, inicialmente têm-se um conjunto de 427 e outro com 128 amostras apresentados na Subseção 5.3.1. As diferenças entre os resultados obtidos a partir do algoritmo 1-NN, com uso de diferentes números de amostras, são apresentadas por meio de imagens e avaliadas em função do Erro Médio Quadrático (*Root Mean Square Error* - RMSE). A análise desses resultados é essencial e tem por objetivo avaliar a qualidade dos resultados do algoritmo em diferentes condições, especialmente com um número variado de amostras de treinamento. A função de avaliação do RMSE é dada a partir da diferença em cada pixel (x, y) entre as imagens, expressa pela Equação 5.5.

$$RMSE = \sqrt{\frac{1}{n_x n_y} \cdot \sum_0^{n_x-1} \sum_0^{n_y-1} [r(x, y) - t(x, y)]^2} \quad (5.5)$$

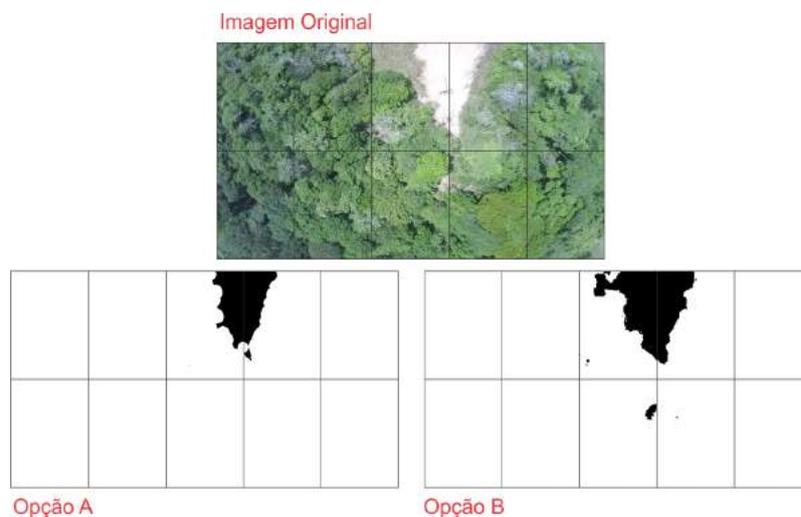
Em que $r(x, y)$ representa as coordenadas dos *pixels* da imagem processada com uso de 427 amostras de treinamento, enquanto que $t(x, y)$ se refere a imagem processada com 128 amostras de treinamento. Ambas devem possuir o mesmo tamanho $[n_x, n_y]$.

Após a escolha do resultado mais apropriado em relação ao algoritmo 1-NN (visto em função da RMSE) com diferentes amostras de treinamento, este será submetido a uma nova análise de comparação, desta vez com o resultado obtido na segmentação baseada em *Watershed*. Para isso, dois grupos de imagens foram selecionados de forma que possam ser analisados independentemente. O primeiro grupo contém 20 imagens de plantio de cana-de-açúcar que será avaliado por um especialista da área de produção agrícola da espécie. O segundo grupo contém 20 imagens aéreas de uma região ambiental composta por vegetação e áreas de degradação, cuja avaliação dos resultados é feita por dois especialistas da área ambiental, com ênfase em mapeamentos de uso e cobertura da terra.

Os grupos de imagens foram fornecidos através de um formulário eletrônico composto por cada imagem original e os dois resultados obtidos pelos diferentes métodos de proces-

samento de imagens utilizados. O método utilizado em cada resultado do processamento não foi divulgado, evitando tendências nos resultados. As imagens foram divididas em dez espaços para facilitar a interpretação dos resultados da segmentação, conforme Figura 5.14. A divisão de cada imagem em dez partes proporciona Além disso, os especialistas foram questionados sobre qual das imagens (Opção A ou B) melhor representaria a imagem original dada e ainda quantos espaços seriam considerados como "sucesso" na classificação (solo exposto ou vegetação) em cada imagem segmentada escolhida. A partir das respostas, a taxa de acerto de cada método pode ser inferida por meio da acurácia, cuja obtenção é calculada pela representação de verdadeiros positivos (VP) e verdadeiros negativos (VN) tratados na Subseção 5.3.2 pela Equação 5.4. No caso, o especialista fornecerá para cada imagem a quantidade de espaços em que, de acordo com sua opinião, houve sucesso na classificação para representar áreas de solo exposto (verdadeiros positivos) e vegetação (verdadeiros negativos), podendo ocorrer as duas classes em um mesmo espaço.

Figura 5.14: Exemplo de imagens enviadas aos especialistas para avaliação dos métodos



Fonte: Próprio autor.

5.5.2 Desempenho em relação ao tempo de execução

Um das métricas mais importantes na avaliação de sistemas embarcados é o tempo para execução de uma determinada tarefa. Esta segunda abordagem trata da verificação de desempenho do algoritmo a partir de medições do tempo de execução do código durante o

processamento das imagens. Analisam-se os resultados do comportamento do algoritmo separadamente em cada plataforma de *hardware* avaliada. As plataformas embarcadas *Intel DE2i-150*, *Intel Edison* e *Raspberry Pi 2*, além do computador pessoal, são utilizadas para avaliar o tempo de processamento gasto com o algoritmo baseado em *Watershed* e 1-NN com 128 instâncias de treinamento. Resultados com 427 instâncias de treinamento são realizados apenas no computador pessoal devido ao alto custo computacional e a semelhança de resultados obtidos com 128 instâncias, dispensando sua avaliação em sistemas embarcados.

O tempo de execução foi medido com precisão de minutos, segundos e centésimos de segundos por meio do *shell script* que recupera informações de data e hora do início e final da execução do programa cada vez que é executado, conforme Código Fonte 5.3

Código Fonte 5.3: Código *Shell script* para cálculo do tempo de processamento

```
1 #/bin/bash
2 d1=$(date +%T.%N)
3 ./Exc_Soft //Execucao do programa
4 d2=$(date +%T.%N)
5 echo $d1;
6 echo $d2;
7 sdate=$(date -u -d "$d1" +"%s.%N")
8 edate=$(date -u -d "$d2" +"%s.%N")
9 echo "Diferenca"
10 date -u -d "0 $edate sec - $sdate sec" +"%H:%M:%S.%N"
```

Capítulo 6

Resultados e Discussão

Este capítulo apresenta os resultados obtidos após a segmentação das imagens e o desempenho do sistema proposto nos sistemas embarcados avaliados em relação a algumas métricas adotadas no projeto.

A Seção 6.1 apresenta os resultados obtidos em relação à qualidade da segmentação de imagens com uso das técnicas *Watershed* e 1-vizinho mais próximo (1-NN). Duas subseções são criadas. A primeira apresenta os resultados obtidos com a variação de dados de treinamento através da técnica 1-NN e seus impactos na segmentação de imagens e taxa de acerto do modelo de dados (Subseção 6.1.1). A segunda trata efetivamente da comparação dos resultados da segmentação entre o algoritmo *watershed* e o algoritmo 1-NN com 128 amostras, cuja análise é feita por especialistas e medida em termos da acurácia (subseção 6.1.2).

A Seção 6.2 apresenta os resultados em relação ao tempo de processamento avaliado em cada algoritmo executado nas plataformas avaliados, e a Seção 6.3 traz resultados em relação ao consumo de energia medido nos sistemas embarcados.

6.1 Avaliação da segmentação

A avaliação da segmentação de imagens é um dos fatores mais importantes na decisão sobre a viabilidade de uso dos algoritmos propostos. Inicialmente, as técnicas foram testadas em um ambiente computacionalmente poderoso comparado com as plataformas embarcadas. A necessidade de adaptação dos algoritmos ou dados utilizados, possibilitou resultados

satisfatórios e possíveis de embarcar a solução em plataformas leves e de baixo consumo.

6.1.1 Variação de dados de treinamento para a técnica 1-NN

Os resultados de testes com o modelo de dados de treinamento são essenciais para verificar a eficiência do modelo a ser utilizado para classificação futura de novos dados. A análise do conjunto de dados permite prever a eficiência do classificador e pode melhorar significativamente o desempenho do sistema. Alguns resultados importantes acerca do modelo de dados utilizado são destacados. O modelo de dados composto por 427 instâncias de treinamento apresenta a matriz de confusão mostrada na Tabela 6.1, a partir do qual é possível estimar uma acurácia de 95,8%. Detalhes sobre o cálculo da acurácia são apresentados na Subseção 5.3.2. Os dados da matriz de confusão mostram que o modelo está melhor rotulando a classe *b* (solo), uma vez que apresenta maior taxa de acerto (97,3%). As instâncias rotuladas como a classe *a* (vegetação) foram corretamente classificadas em 93,6% dos casos.

Tabela 6.1: Matriz de confusão do algoritmo 1-NN com 427 instâncias com parâmetro N=10

Expectativa	Classificação <i>a</i>	classificação <i>b</i>	Acurácia
Classe a	160	11	93,6%
Classe b	7	249	97,3%

O algoritmo 1-NN também foi avaliado com 128 amostras de treinamento e conseguiram melhores resultados, uma vez que níveis mais altos de acurácia foram encontrados, como pode ser visto a partir da matriz de confusão mostrada na Tabela 6.2. Neste caso, os dados da matriz de confusão mostram que o modelo está mais equilibrado do que o anterior. Os dados apontam uma taxa de acerto da classe *a* (vegetação) de 98,2% e para a classe *b* (solo) igual a 97,2%. Resultando em uma acurácia de 97,6%, considerando as duas classes avaliadas.

Tabela 6.2: Matriz de confusão do algoritmo 1-NN com 128 instâncias com parâmetro N=10

Expectativa	Classificação <i>a</i>	classificação <i>b</i>	Acurácia
Classe a	56	1	98.2%
Classe b	2	69	97.2%

Os resultados de processamento de imagens da área de preservação ambiental (APA) podem ser vistos na Tabela 6.4 e da região agrícola de cana de açúcar na Tabela 6.5. Apresentam-se os resultados da segmentação utilizando o algoritmo 1-NN com 427 e 128

instâncias de treinamento, em que áreas preenchidas pela cor preto representam solo exposto na imagem. A comparação entre os resultados do processamento das imagens com uso de 427 instâncias de treinamento e com 128 instâncias é realizada em função do Erro Médio Quadrático (RMSE) calculado entre elas. Imagens com maior semelhança apresentam valores de RMSE mais baixos. A diferença entre imagens processadas com uso de 427 e 128 instâncias de treinamento, dada em termos da RMSE, é apresentada na Tabela 6.3.

Tabela 6.3: RMSE entre imagens processadas com 427 e 128 amostras

Imagens da APA		Imagens do plantio de cana	
Imagem	RMSE	Imagem	RMSE
APA 1	27,46	Cana de açúcar 1	74,47
APA 2	18,81	Cana de açúcar 2	54,89
APA 3	63,83	Cana de açúcar 3	35,09
APA 4	36,23	Cana de açúcar 4	71,58
APA 5	34,53	Cana de açúcar 5	73,49
APA 6	27,27	Cana de açúcar 6	78,10
Média	34,09	Média	64,61

Nota-se que na segmentação com 128 instâncias as áreas de menor intensidade de solo foram segmentadas como solo exposto, porém não prejudica significativamente a etapa de segmentação.

Os resultados indicam que as imagens da região ambiental possuem maior tolerância à redução do número de instâncias utilizadas, em que o erro calculado apresenta níveis mais baixos em comparação com as imagens do plantio de cana de açúcar na maioria dos casos. Isso representa menor variação na etapa de segmentação das imagens após a redução do conjunto de treinamento. O melhor caso pertence ao grupo de imagens ambientais, em que a imagem "APA 2" registrou o menor erro encontrado. O pior caso encontrado pertence ao grupo de imagens de cana de açúcar e foi registrado na imagem "Cana de açúcar 6" em que o maior erro foi verificado. Apesar disso, é possível perceber visualmente que a imagem em questão, segmentada com 128 amostras de treinamento, apesar de apresentar o pior resultado, não compromete consideravelmente a segmentação obtida com 427 amostras.

Tabela 6.4: Resultados do processamento através da técnica do 1-vizinho mais próximo com 427 e 128 amostras de treinamento para imagens da APA

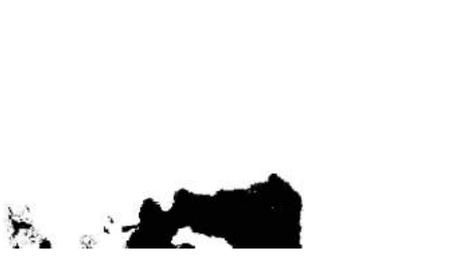
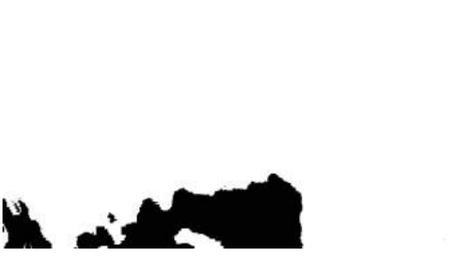
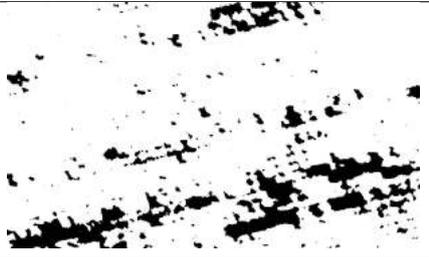
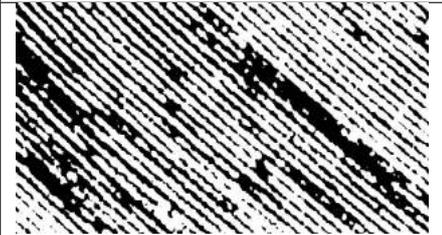
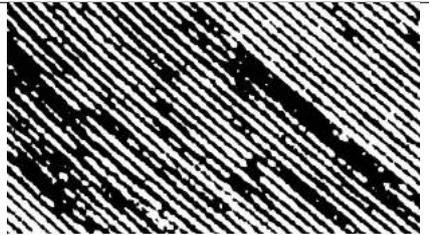
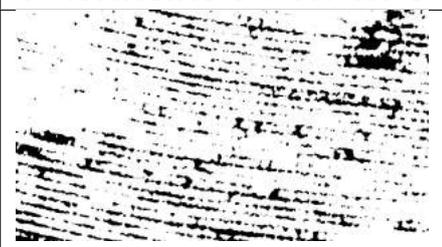
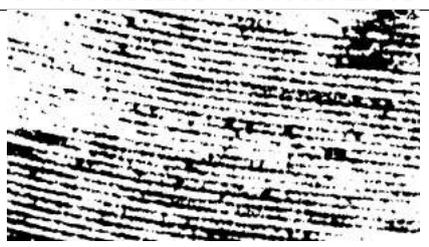
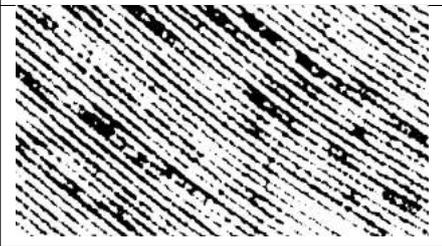
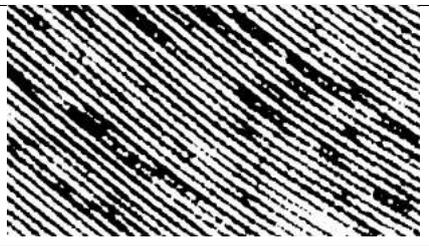
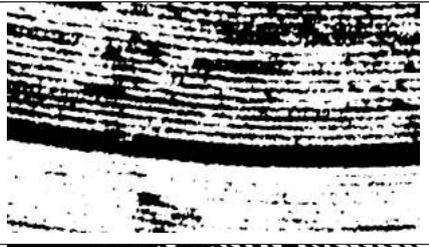
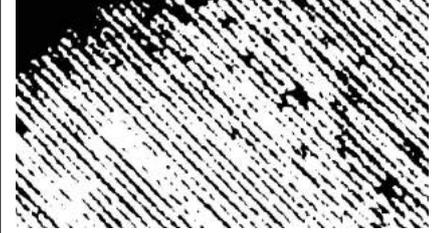
Imagem	427 amostras	128 amostras
APA 1		
APA 2		
APA 3		
APA 4		
APA 5		
APA 6		

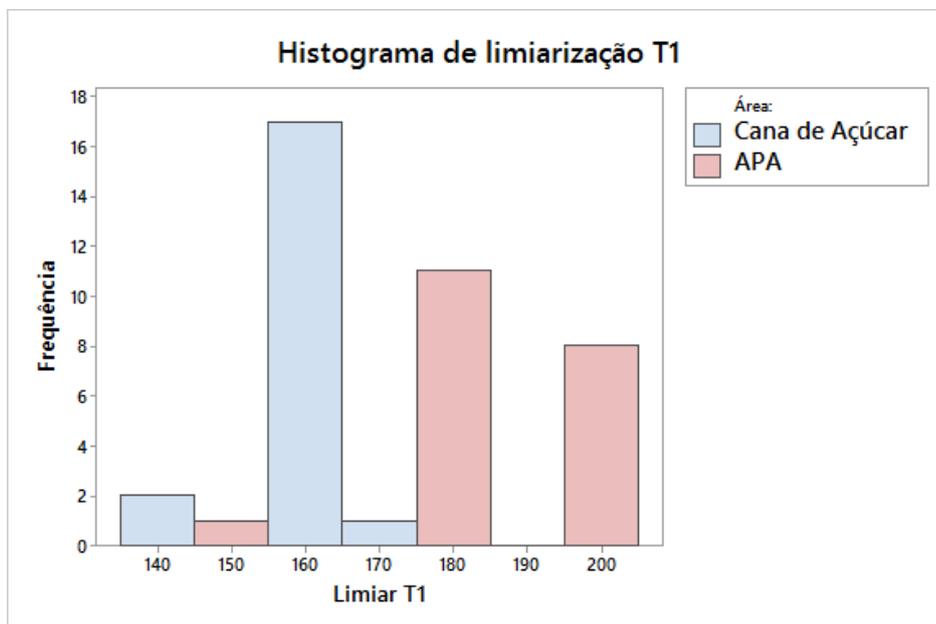
Tabela 6.5: Resultados do processamento através da técnica do 1-vizinho mais próximo com 427 e 128 amostras de treinamento para imagens da região agrícola de cana de açúcar

Imagem	427 amostras	128 amostras
Cana de açúcar 1		
Cana de açúcar 2		
Cana de açúcar 3		
Cana de açúcar 4		
Cana de açúcar 5		
Cana de açúcar 6		

6.1.2 Comparação de resultados

As imagens aéreas utilizadas e os respectivos resultados de processamento a partir das técnicas baseadas em *watershed* e 1-NN são apresentados nesta subseção. Conforme esperado, as imagens processadas por meio do método baseado em *watershed* utilizaram valores de limiar específicos devido à variação de luminosidade presente em cada grupo de imagens. A Figura 6.1 mostra um histograma com a frequência de valores configurados na primeira etapa de limiarização (T_1) durante o processamento de imagens. Três níveis do limiar T_1 são configurados para os dois grupos de imagens, sendo que imagens de cana de açúcar apresentaram níveis mais baixos de limiar T_1 em comparação com as imagens da área da preservação. Valores de limiar T_1 entre o intervalo 155 – 165 foram predominantemente escolhidos durante o grupo de imagens de cana de açúcar e utilizados em 85% das imagens. A maior predominância presente no grupo de imagens da região ambiental utilizam valores de limiar T_1 entre 175 – 185 em 55% dos casos. A moda encontrada para os valores de T_1 em relação às imagens de cana de açúcar e da APA foram 160 e 175, respectivamente.

Figura 6.1: Histograma de frequência da limiarização T_1

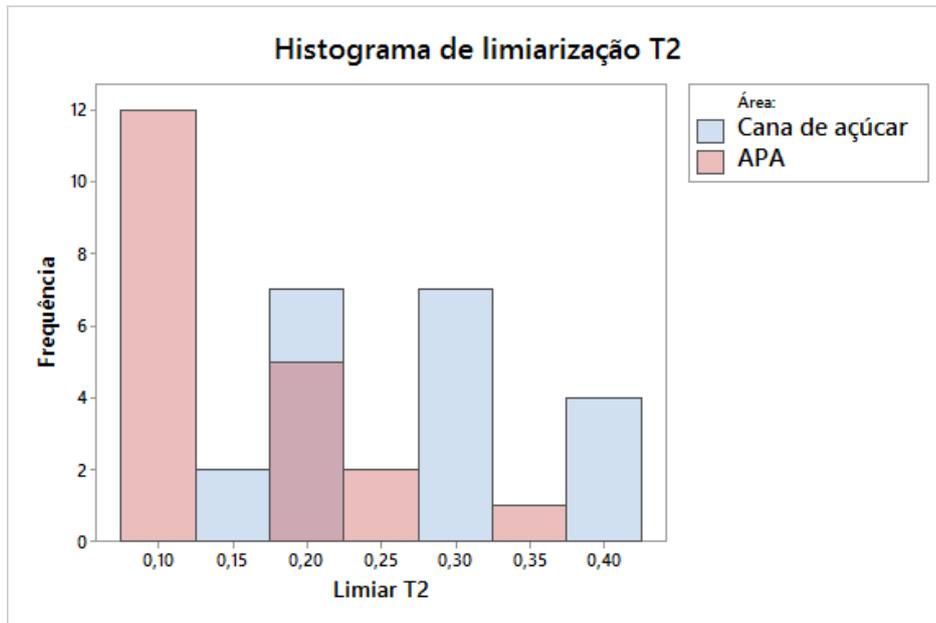


Fonte: Próprio autor.

Dados da segunda etapa de limiarização (T_2) são representados por meio do histograma mostrado Figura 6.2. Esta etapa apresentou maior variação de dados do que a primeira,

principalmente nas imagens de cana-de-açúcar em que a concentração máxima foi 35%, observada entre os intervalos $[0,175 - 0,225]$ e $[0,275 - 0,325]$. Os níveis de limiar $T2$ definidos em imagens ambientais se concentram em níveis mais baixos, entre o intervalo $[0,075 - 0,125]$ em 60% dos casos. A moda obtida para os valores $T2$ para imagens de cana-de-açúcar são os valores 0,22 e 0,30, e para a APA o valor 0,10 foi o mais frequente.

Figura 6.2: Histograma de frequência da limiarização $T2$

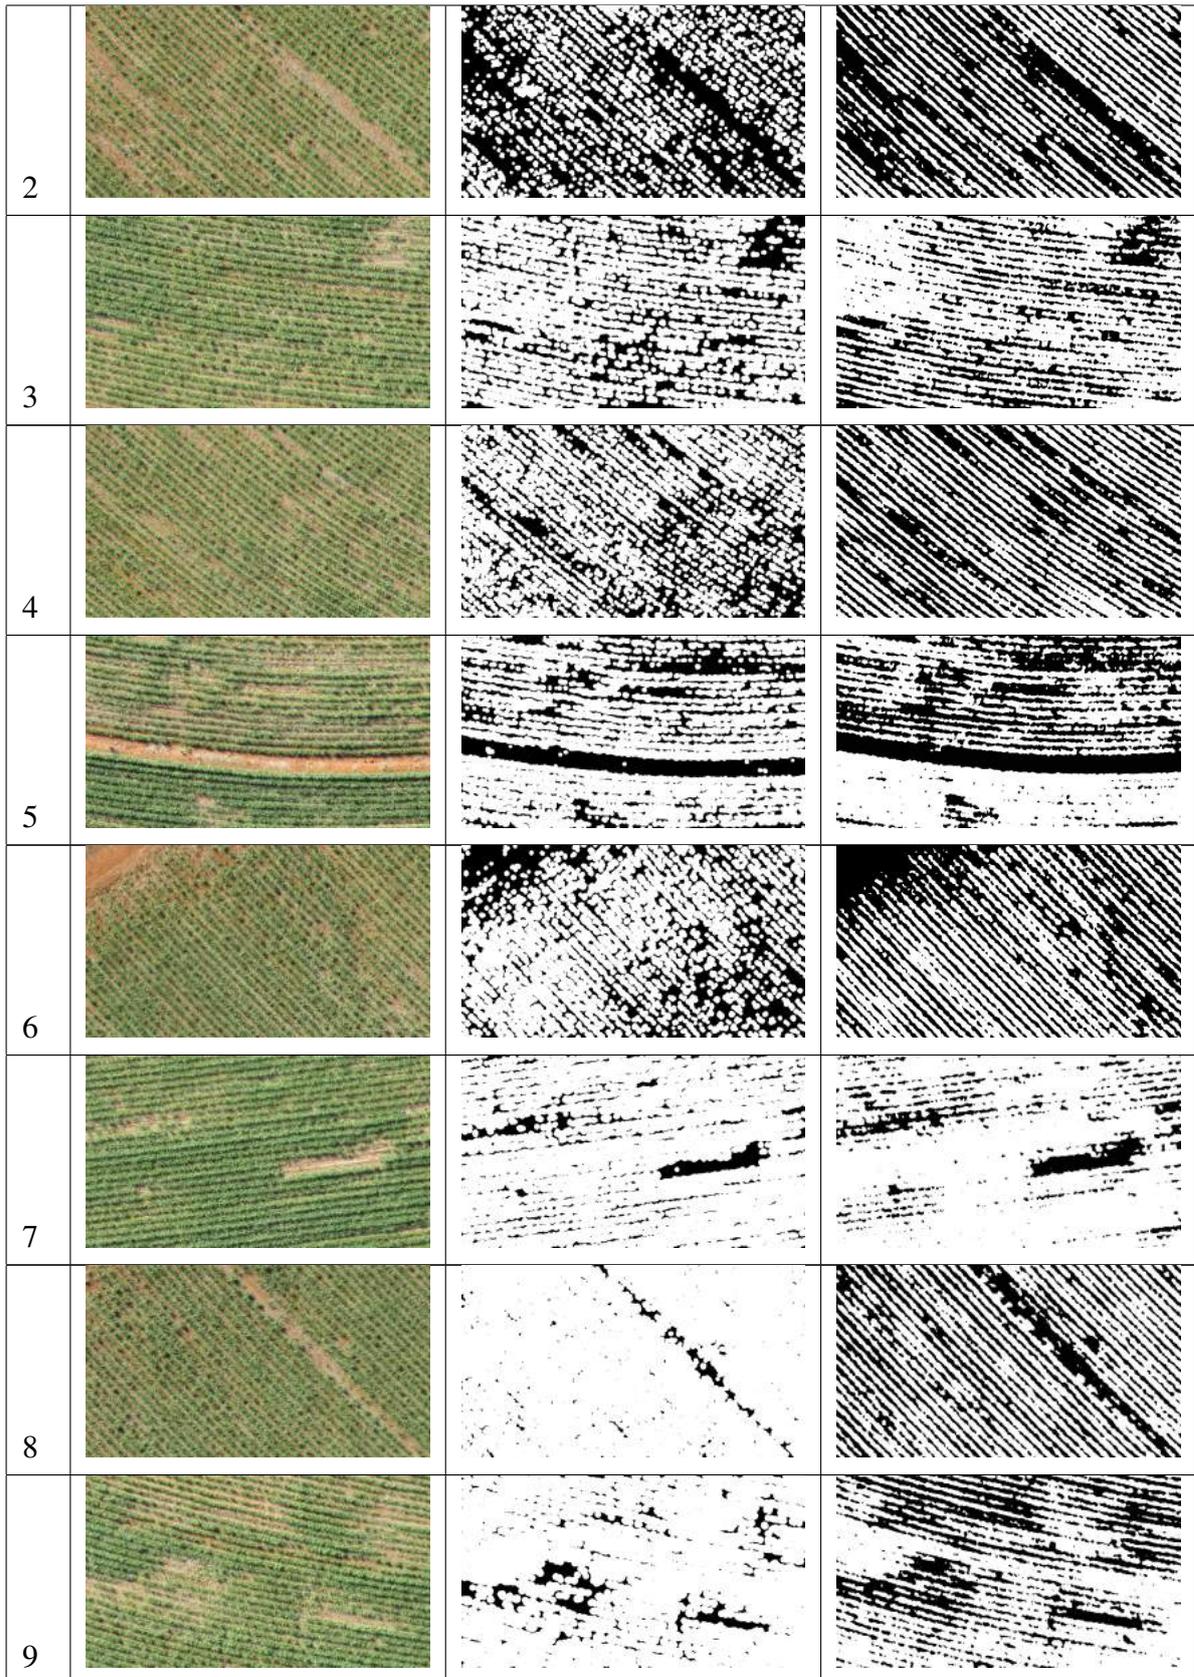


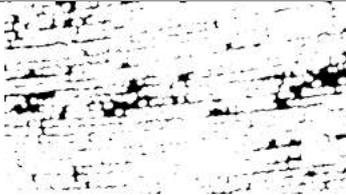
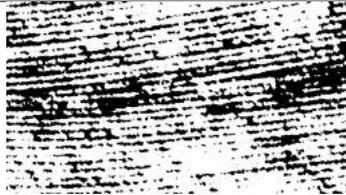
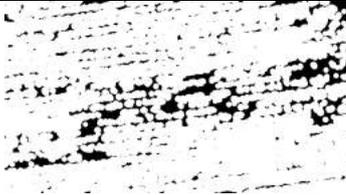
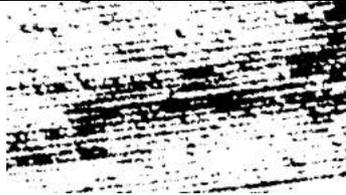
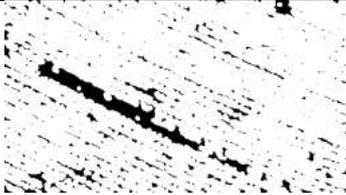
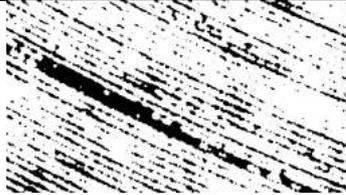
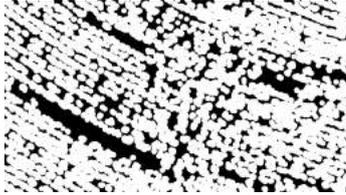
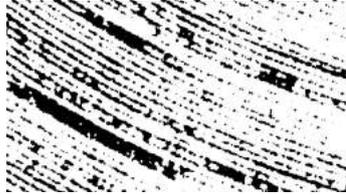
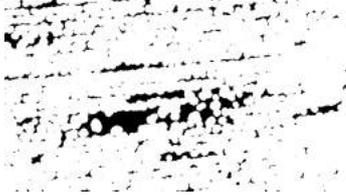
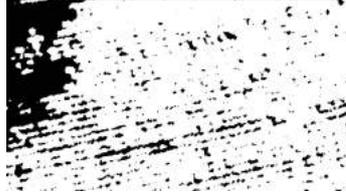
Fonte: Próprio autor.

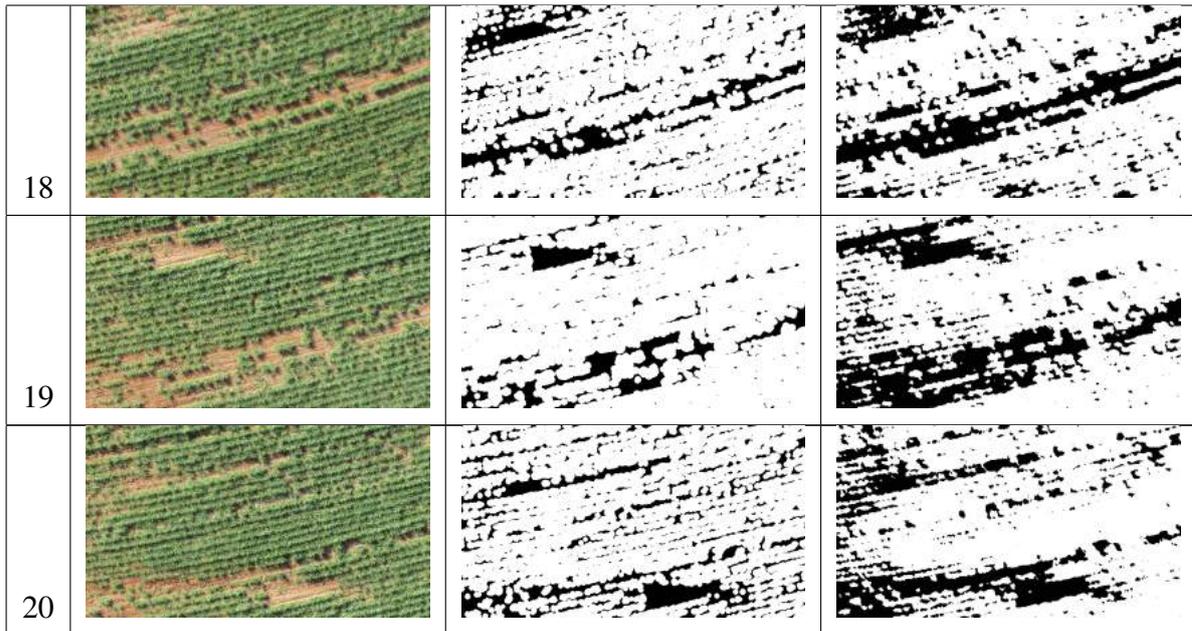
Imagens do plantio de cana-de-açúcar e seus resultados de processamento utilizando os métodos *watershed* e 1-NN com 128 instâncias de treinamento são mostrados na Tabela 6.6.

Tabela 6.6: Imagens originais e segmentadas através das técnicas baseadas em *watershed* e 1-NN com 128 instâncias de treinamento para região agrícola

i	Imagem Original	<i>watershed</i>	<i>1-vizinho mais próximo</i>
1			



10			
11			
12			
13			
14			
15			
16			
17			



As imagens do plantio de cana-de-açúcar foram analisadas por um especialista que em 90% dos casos apontou como o melhor resultado as imagens segmentadas pela técnica 1-NN. A Tabela 6.7 mostra os resultados das escolhas do especialista para cada uma das 20 imagens aéreas analisadas.

Tabela 6.7: Escolha do especialista para representação do melhor método de segmentação a partir de experimentos com 20 imagens da região de cana-de-açúcar

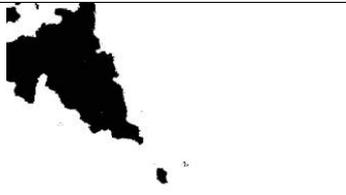
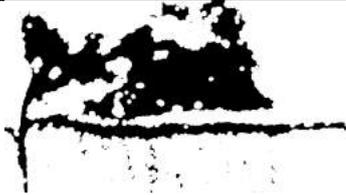
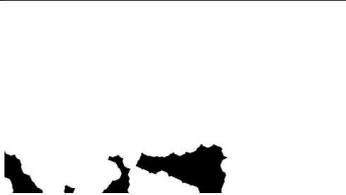
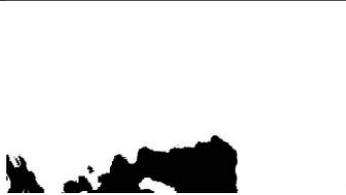
	<i>Imagem</i>																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Watershed			•				•													
1-NN	•	•		•	•	•		•	•	•	•	•	•	•	•	•	•	•	•	•
VP+VN	10	10	9	8	10	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9

A marcação de um ponto na tabela representa o respectivo método escolhido pelo especialista como o melhor resultado, enquanto que a numeração dada em $VP + VN$ representa a quantidade total de acertos na imagem escolhida, obtida através da soma de verdadeiros positivos (VP) e verdadeiros negativos (VN). Neste caso, entende-se como VP as áreas que contenham pontos classificados corretamente como solo exposto e VN as áreas que contenham pontos classificados corretamente como vegetação, podendo haver espaços que contenham as duas classes concomitantemente. Considerando que houve a avaliação do especialista em 20 imagens subdivididas em um total de 200 espaços, pode-se, a partir das respostas, estimar uma acurácia de 91% para imagens segmentadas pelo método 1-NN. Apesar de apenas

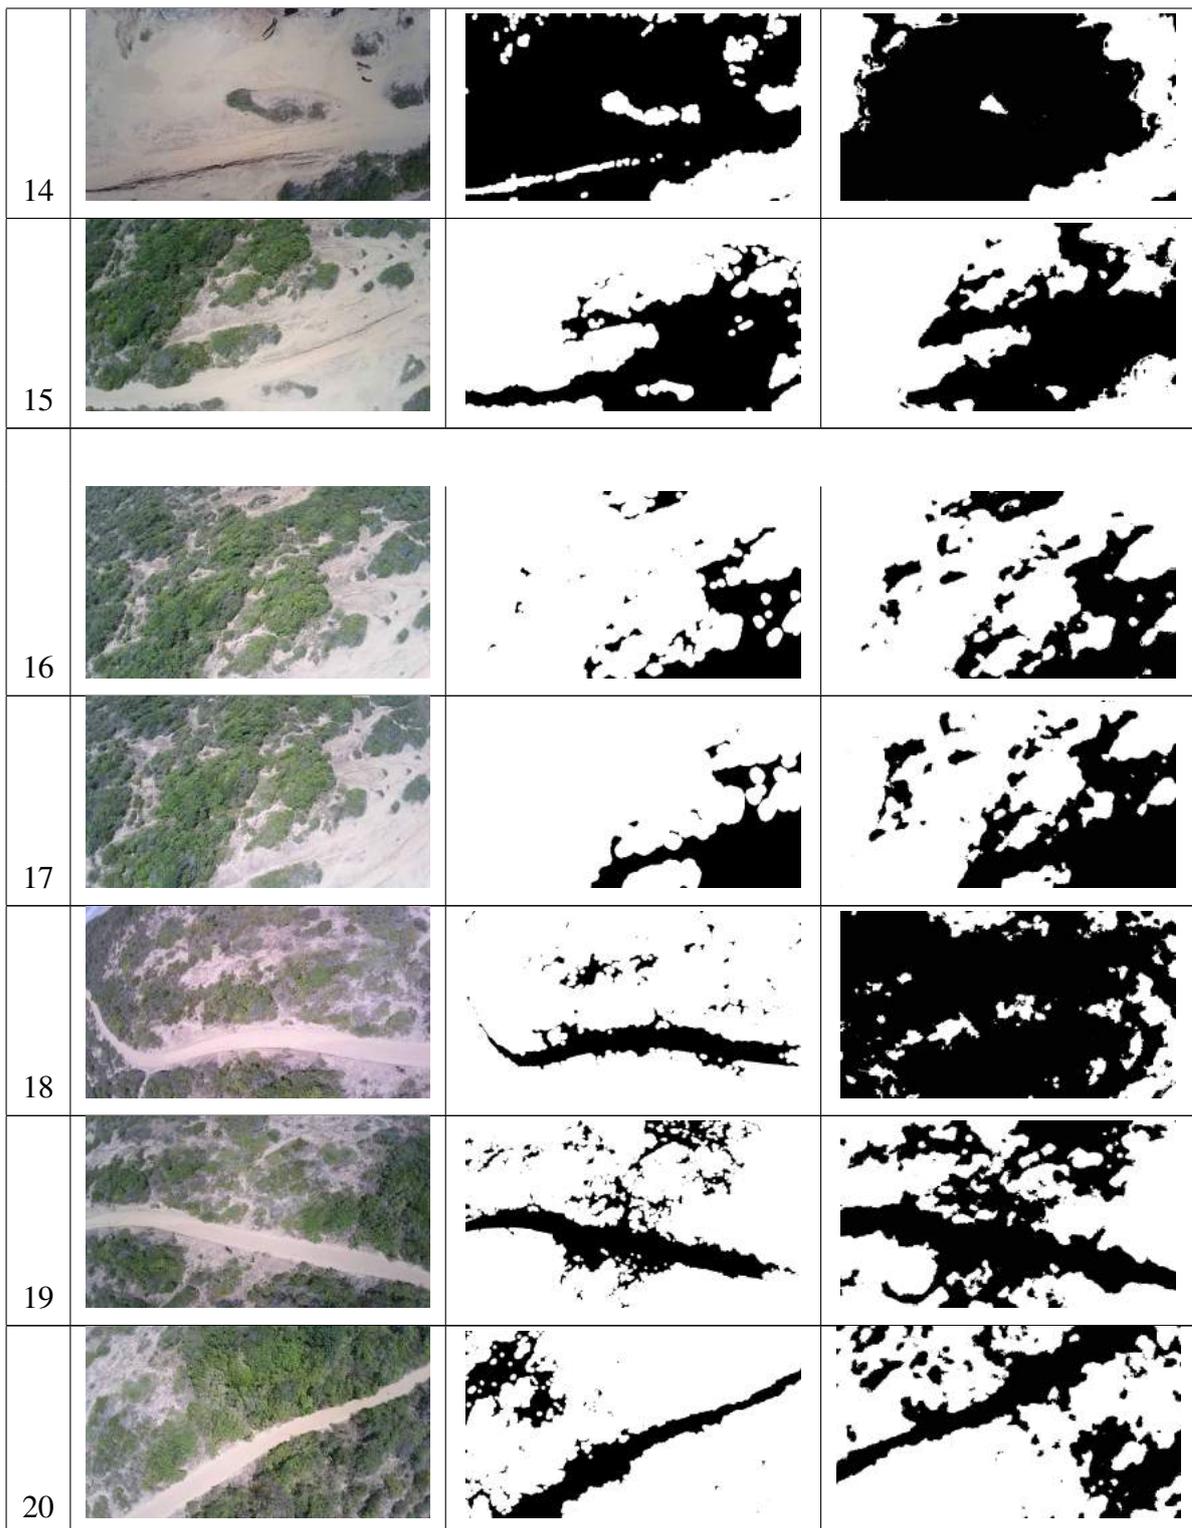
10% dos resultados escolhidos pelo especialista como a melhor representação ter sido obtido pela técnica *watershed*, esta também apresenta níveis de acurácia satisfatórios que giram em torno de 90%.

Os resultados da segmentação das imagens da área de preservação ambiental utilizando as técnicas abordadas neste trabalho são apresentados na Tabela 6.8. O julgamento de dois especialistas apontam que a técnica baseada em *watershed* é a mais indicada para análises ambientais.

Tabela 6.8: Imagens originais e segmentadas através das técnicas baseadas em *watershed* e 1-NN com 128 instâncias de treinamento para região ambiental

<i>i</i>	Imagem Original	<i>watershed</i>	<i>1-vizinho mais próximo</i>
1			
2			
3			
4			
5			

6			
7			
8			
9			
10			
11			
12			
13			



Considerando o total de 20 imagens aéreas da região ambiental, 75% obtiveram melhor resultado a partir da técnica baseada em *watershed*, enquanto que o método baseado em 1-NN foi escolhido em 10% das imagens, considerando a opinião de ambos especialistas. Em

15% dos casos houve divergências de opiniões quanto à escolha do método que melhor representaria a respectiva imagem original. Os dados detalhados sobre as escolhas dos especialistas quanto à segmentação das imagens analisadas são mostrados na Tabela 6.9. Os dados de VP e VN foram obtidos por meio da média quando escolhido a mesma técnica por ambos especialistas, enquanto que tais valores foram desconsiderados na ocasião de divergência das opiniões destes. Da mesma forma que o grupo de imagens anteriormente avaliado, denota-se como VP as áreas que contenham pontos classificados corretamente como solo exposto e VN as áreas que contenham pontos classificados corretamente como vegetação, podendo haver espaços que contenham as duas classes concomitantemente. Entende-se como a soma $VP + VN$ a quantidade dos espaços julgados pelo especialista em que houve total acerto na classificação de solo ou vegetação. Neste caso, a estimativa de dados de acurácia foi baseada em um total de 400 avaliações de espaços de imagens, considerando a análise de 20 imagens subdividida em dez partes e cada uma avaliada por dois especialistas. A partir dos dados obtidos por ambos especialistas, é possível inferir que a técnica baseada em *watershed* alcançou níveis de acurácia estimados em 80,3%. Apesar da escolha dos resultados baseados na técnica 1-NN não ser majoritário, as imagens selecionadas com esta técnica apresentam níveis de acurácia mais altos, em torno de 87% para imagens ambientais.

Tabela 6.9: Escolha do especialista para representação do melhor método de segmentação a partir de experimentos com 20 imagens da região ambiental

	<i>Imagem</i>																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Watershed	•	•	•	•	•	•	•	•	•	•	•	•		•	•	•		•	•	•
1-NN					•								•			•	•			•
VP+VN	8	8,5	8,5	7,5	-	9	8,5	8	6,5	8	8,5	8,5	8,5	8	8	-	9	7,5	7,5	-

As técnicas apresentadas neste trabalho possuem resultados satisfatórios. O algoritmo baseado em *watershed* possui menor robustez, uma vez que seu desempenho em relação à acurácia ainda é fortemente dependente dos valores de limiar $T1$ e $T2$ previamente definidos. Isso pode culminar em problemas de natureza humana como, por exemplo, a subjetividade da avaliação.

A redução da quantidade de amostras de treinamento a partir da técnica do 1-vizinho mais próximo não interfere significativamente na qualidade da segmentação das imagens. Portanto, pode-se utilizar o conjunto reduzido de amostras para a segmentação de imagens

sem prejuízos significativos.

Os resultados apresentados nesta seção são similares aos mostrados em (FELIZARDO et al., 2013) e (MOTA et al., 2013) que utiliza redes neurais artificiais para a segmentação das imagens, porém necessitam de intervenção humana durante a etapa de pré-processamento. Ao contrário, este trabalho evolui para dispensar totalmente a interferência humana por meio da aplicação de técnicas de aprendizagem de máquina (AM), ou parcialmente, automatizando a etapa de pré-processamento na técnica baseada em *watershed*. Além disso, o uso de técnicas mais simples podem viabilizar a capacidade do sistema proposto de ser implantado em sistemas embarcados.

Os resultados da aplicação do algoritmo para a estimativa de áreas de degradação nas imagens ambientais podem ser vistos na Tabela 6.10, que apresenta os percentuais de solo exposto obtidos pelo algoritmo baseado em *watershed* e 1-NN após o processamento das imagens da área de preservação ambiental (APA) analisadas. O desenvolvimento de novas funcionalidades agregadas aos algoritmos propostos apresentam elevado potencial de uso em estudos de conservação de ambientes naturais, que segundo os especialistas, permitem auxiliar nas tarefas de acompanhamento temporal da evolução de determinado fenômeno, como por exemplo, a inspeção de mortalidade ou revitalização da vegetação.

Tabela 6.10: Percentual de solo exposto em imagens ambientais

Solo exposto (%)			Solo exposto (%)		
Imagem	<i>Watershed</i>	1-NN	Imagem	<i>Watershed</i>	1-NN
APA 1	8,3	14	APA 11	7,6	34
APA 2	3,6	5	APA 12	11,3	31
APA 3	20,3	46	APA 13	47,9	63
APA 4	28,8	89	APA 14	80	75
APA 5	5,8	10	APA 15	35,4	41
APA 6	4,55	10	APA 16	16,3	29
APA 7	3,5	5	APA 17	16,9	34
APA 8	24,3	20	APA 18	20	84
APA 9	22,3	26	APA 19	17,3	32
APA 10	28,2	33	APA 20	22,16	35

6.2 Tempo de processamento

O tempo de execução do algoritmo utilizando a técnica 1-NN é diretamente proporcional ao tamanho do conjunto de dados de treinamento. A Tabela 6.11 mostra os resultados em relação ao tempo de processamento verificado em um grupo composto por doze imagens testadas com 427 e 128 amostras de treinamento. Os testes foram realizados em um computador pessoal. A redução do conjunto de treinamento em 70% reduziu em aproximadamente 68% a média do tempo de processamento.

Considerando que a redução de quantidade de amostras utilizando o algoritmo 1-NN não interfere significativamente no resultado da segmentação de imagens, conforme visto na Seção 6.1, apenas o conjunto composto por 128 amostras será utilizado nos sistemas embarcados para comparação com o algoritmo baseado em *watershed*. Os algoritmos foram avaliados separadamente em cada plataforma.

Tabela 6.11: Tempo de processamento com uso do algoritmo baseado em 1-NN

Treinamento	Média (<i>em seg.</i>)	Melhor caso (<i>em seg.</i>)	Pior caso (<i>em seg.</i>)
427 amostras	42,75	41,0	46,6
128 amostras	13,84	12,8	15,63

Os resultados do algoritmo baseado em *watershed* em relação ao tempo médio de processamento, além do melhor e pior resultado para o grupo de imagens analisado, são mostrados na Tabela 6.12. Conforme esperado, a plataforma que registra o melhor caso observado é o computador pessoal, devido à alta capacidade computacional. Entre os sistemas embarcados, a plataforma *DE2i-150* apresentou os melhores resultados para o algoritmo inicialmente avaliado, registrando em média de 0,88 segundos para o processamento de uma imagem.

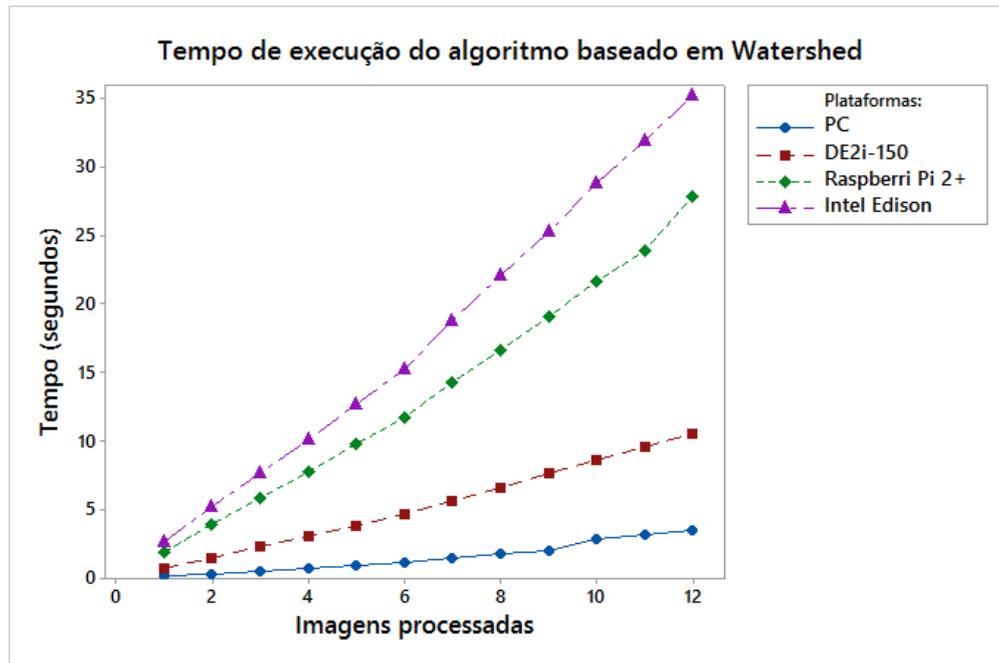
Tabela 6.12: Tempo de execução do algoritmo baseado em *watershed*

Plataforma	Média (<i>em seg.</i>)	Melhor caso (<i>em seg.</i>)	Pior caso (<i>em seg.</i>)
Computador Pessoal	0,29	0,18	0,84
<i>DE2i-150</i>	0,88	0,74	1,05
<i>Intel Edison</i>	2,93	2,40	3,50
<i>Raspberry pi 2+</i>	2,32	1,93	3,90

Considerando as plataformas *Intel Edison* e *Raspberri Pi 2* como as duas possíveis plataformas a serem acopladas a um VANT avaliadas em (SILVA et al., 2015b), a segunda

apresentou desempenho superior para o algoritmo baseado em *watershed*, com redução de 20,8% no tempo médio de processamento em relação à primeira. A Figura 6.3 mostra o tempo de execução durante o processamento do grupo composto por 12 imagens aéreas utilizando o algoritmo baseado em *watershed*.

Figura 6.3: Tempo para o processamento de imagens utilizando a técnica baseada em *watershed* em diferentes plataformas



Fonte: Próprio autor.

O mesmo grupo de imagens foi executado a partir da técnica baseada do 1-vizinho mais próximo. Da mesma forma, os melhores resultados foram observados no computador pessoal e na plataforma embarcada *DE2i-150*. Considerando as plataformas capazes de serem acopladas a um VANT, o melhor resultado identificado ocorreu com a plataforma embarcada *Intel Edison*, que registrou uma média de 102 segundos para realizar o processamento de cada imagem, resultado 25,3% superior à plataforma embarcada *Raspberri Pi 2* para a execução do algoritmo 1-NN. A Figura 6.4 mostra os resultados de tempo de execução para as 12 imagens processadas anteriormente, assim como a Tabela 6.13 apresenta dados mais detalhados sobre os resultados do tempo de execução do algoritmo.

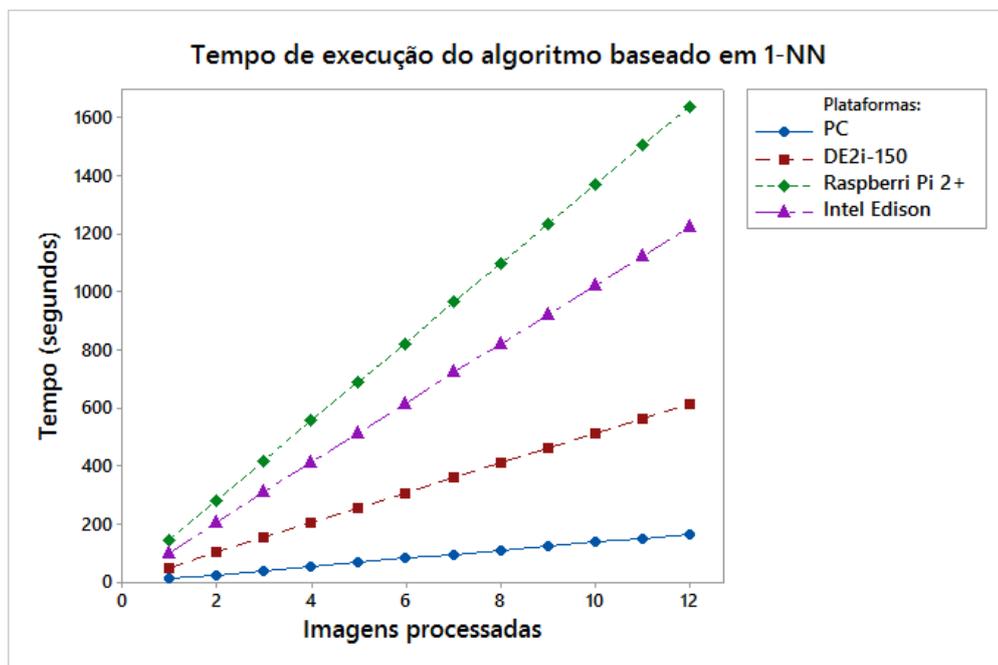
Os resultados encontrados pela plataforma *Raspberri Pi 2* poderão ser melhorados com a utilização de um dispositivo de armazenamento com maior velocidade de transferência

de dados, tendo em vista que foi utilizado um cartão micro SD série 4 com capacidade de transferência 4 MB/s, que representa uma taxa inferior comparada aos dispositivos de armazenamento utilizados nas demais plataformas embarcadas (SSD e armazenamento interno), podendo influenciar diretamente no desempenho do sistema.

Tabela 6.13: Tempo de execução do algoritmo baseado em 1-NN

Plataforma	Média (em seg.)	Melhor caso (em seg.)	Pior caso (em seg.)
Computador Pessoal	13,84	12,8	15,63
<i>DE2i-150</i>	51,22	50,4	53,9
<i>Intel Edison</i>	102	100	107
<i>Raspberry pi 2+</i>	136,5	130	147

Figura 6.4: Tempo para o processamento de imagens utilizando a técnica baseada em 1-NN em diferentes plataformas



Fonte: Próprio autor.

A partir dos dados extraídos dos gráficos apresentados, é possível observar que a plataforma de arquitetura ARM (*Raspberry Pi 2*) apresentou menor rendimento com uso do algoritmo baseado em 1-NN (Figura 6.4), demandando maior tempo para o processamento das imagens, ao contrário do que ocorreu com a técnica baseada em *watershed*, em que a mesma plataforma apresentou desempenho superior, visto pelo menor tempo para o processamento

do grupo de imagens (Figura 6.3). Isso pode ter ocorrido em consequência de características específicas de arquitetura x86 como, por exemplo, as técnicas de microprogramação que interferem positivamente no cálculo ou no tratamento de instruções. Essa hipótese é baseada considerando os cálculos que envolvem as métricas de distância presentes no algoritmo 1-NN, como por exemplo, a distância Euclidiana que requer muitos cálculos aritméticos que provavelmente se beneficiam com as técnicas incluídas em processadores x86, e por isso a plataforma *Intel Edison* apresenta maior destaque.

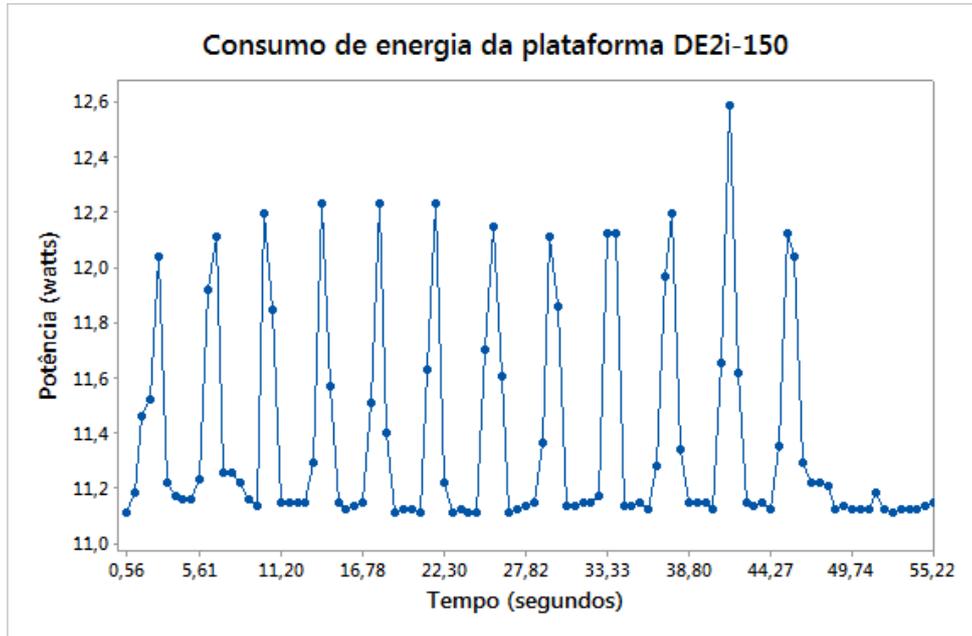
6.3 Eficiência energética

Um circuito baseado em hardware *arduino* foi utilizado para medir o consumo de corrente durante a execução do código nos sistemas embarcados a partir das técnicas baseadas em *watershed* e 1-NN. Com o objetivo de verificar a variação dos níveis de consumo de energia nas plataformas avaliadas durante o processamento de cada imagem, um *script* foi configurado para processar as imagens sequencialmente com um intervalo de dois ou três segundos entre elas, de modo que seja possível visualizar a variação de corrente elétrica consumida.

O consumo de energia observado ao longo dos testes na plataforma *DE2i-150*, considerando a tensão de entrada igual a 12 V, durante a execução do algoritmo baseado em *watershed* apresentou consumo em torno de 12,24 W e pico em torno de 12,60 W. Durante o intervalo em que o algoritmo não estava em execução (configurado para 2 segundos), os níveis de consumo elétrico registrados ficaram em torno de 11,04 W, representando o consumo nominal da placa. Os níveis de consumo durante o processamento com o grupo de imagens, a partir do algoritmo *watershed*, são mostrados na Figura 6.5. Durante os testes foram utilizados cerca de 50 segundos para o processamento das imagens.

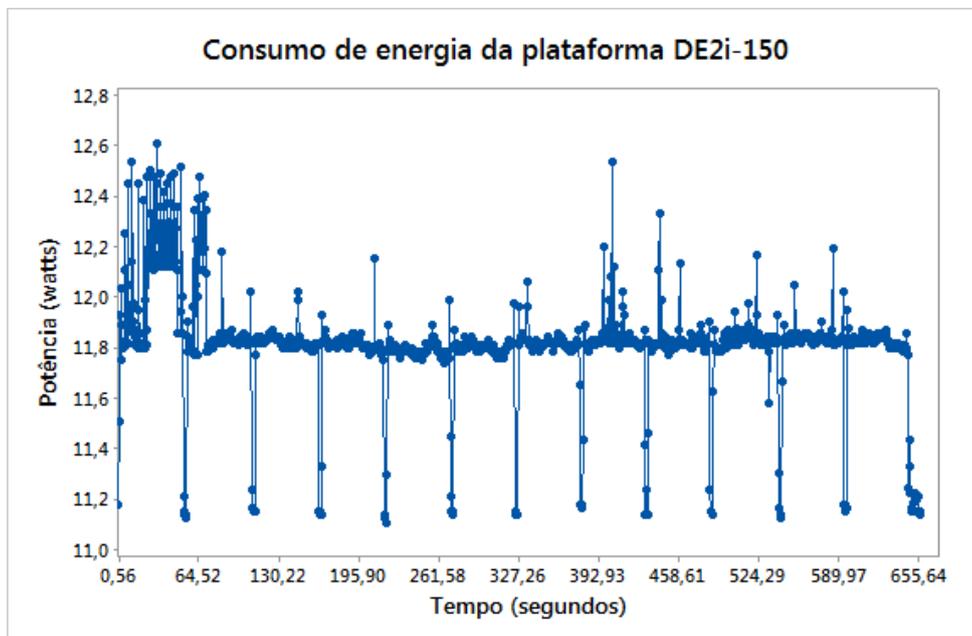
Considerando ainda a plataforma *DE2i-150*, desta vez com uso do algoritmo baseado em 1-NN, intervalo entre processamento de imagens configurado para 3 segundos e sob as mesmas condições de testes e imagens utilizadas, foram encontrados resultados em relação ao consumo nominal e pico equivalentes. Porém, devido ao elevado tempo de execução e, conseqüentemente, registros na maior parte do tempo com níveis mais elevados de consumo elétrico, a potência média de consumo (P_{media}) foi elevada consideravelmente, registrando 11,80 W. O tempo total de avaliação foi de aproximadamente 660 segundos (11 minutos).

Figura 6.5: Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo *watershed* na plataforma *DE2i-150*



Fonte: Próprio autor.

Figura 6.6: Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo 1-NN na plataforma *DE2i-150*

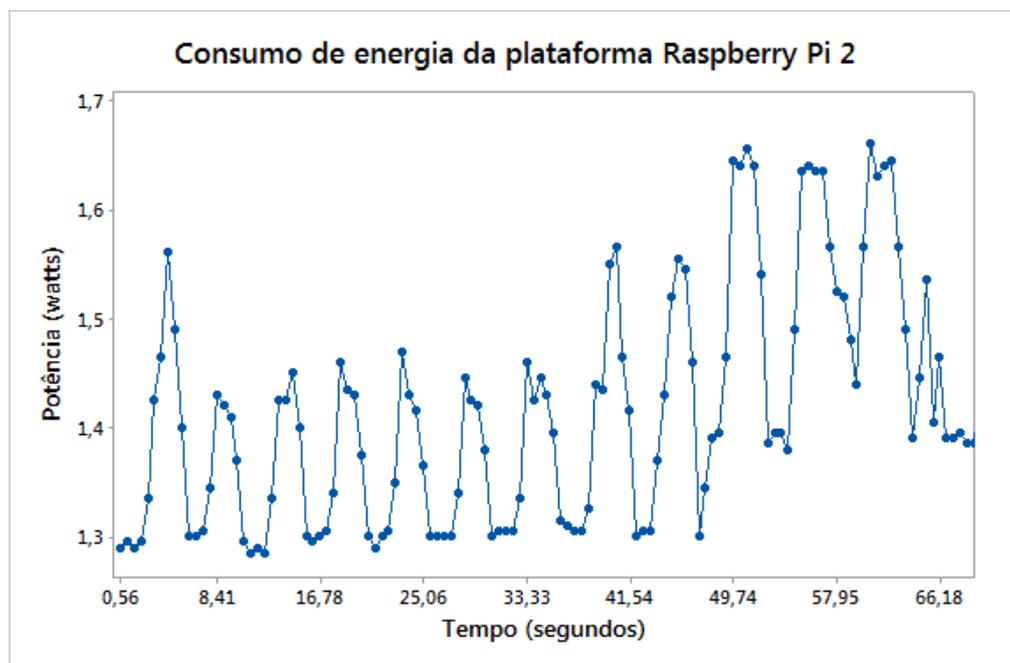


Fonte: Próprio autor.

Os níveis de consumo podem ser observados na Figura 6.6.

A plataforma *Raspberry Pi 2* apresentou durante a execução do algoritmo baseado em *watershed* níveis de consumo de energia em torno de 1,40 a 1,55 W, considerando a tensão de entrada igual a 5 V, com picos entre 1,50 e 1,65 W. Durante o intervalo em que o algoritmo não estava em execução (2 segundos), os níveis de consumo elétrico registrados apontaram uma potência nominal em torno de 1,30 W. O tempo de avaliação total durante o processamento das imagens foi de, aproximadamente, 70 segundos. Os níveis de consumo durante o processamento com uso do algoritmo *watershed* são mostrados na Figura 6.7. Utilizando a mesma plataforma, desta vez com uso do algoritmo baseado em 1-NN e intervalo de 3 segundos, obtêm-se o gráfico apresentado na Figura 6.8. Houve redução dos níveis de consumo, aferidos entre 1,30 e 1,45 W durante o processamento das imagens, com picos de, no máximo, 1,50 W na maior parte do tempo analisado. O tempo total de avaliação do processamento para as imagens testadas foi de aproximadamente 1500 segundos (25 minutos).

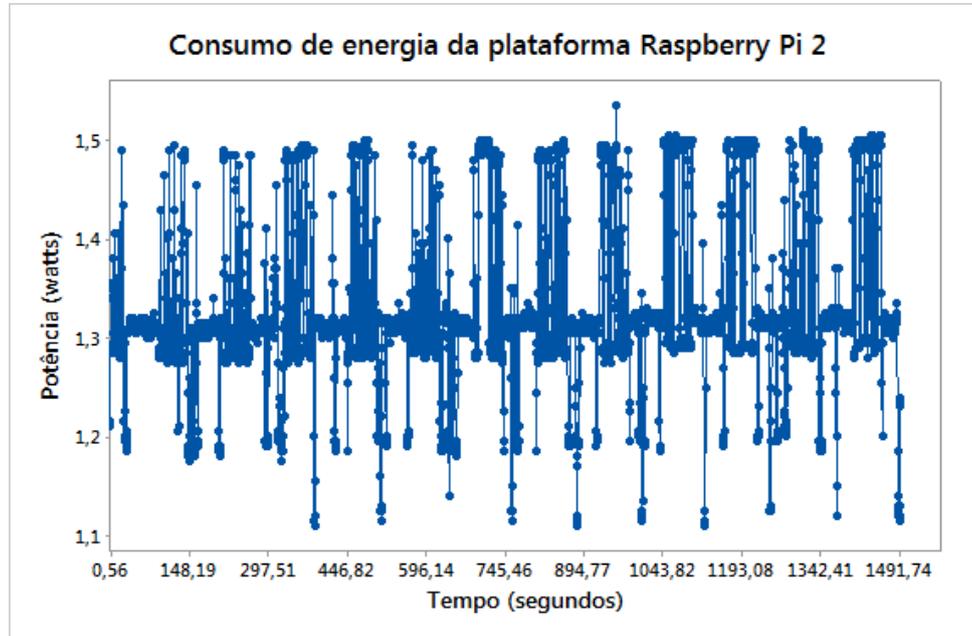
Figura 6.7: Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo *watershed* na plataforma *Raspberry Pi 2*



Fonte: Próprio autor.

O sistema embarcado *Intel Edison* apresentou o menor consumo de energia avaliado. Durante a execução do algoritmo baseado em *watershed* registrou-se uma potência média

Figura 6.8: Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo 1-NN na plataforma *Raspberry Pi 2*



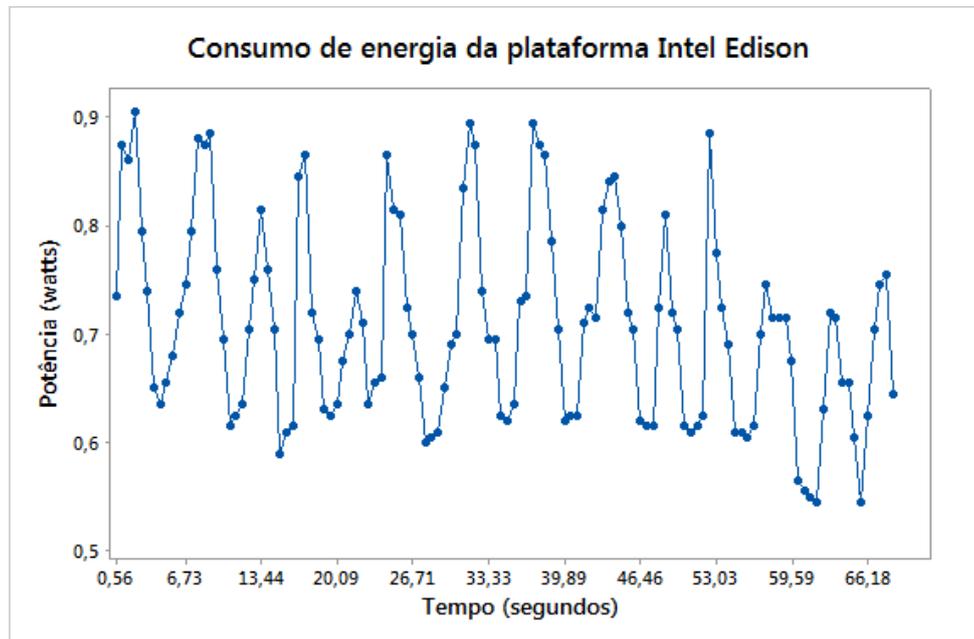
Fonte: Próprio autor.

em torno de 700 mW, com picos entre 850 e 900 mW. Enquanto que durante o intervalo em que o algoritmo não estava em execução (2 segundos) foi verificada uma potência nominal em torno de 550 mW. O tempo de avaliação total durante o processamento das imagens foi de aproximadamente 60 segundos. Os níveis de consumo durante o processamento com uso do algoritmo *watershed* são mostrados na Figura 6.9.

A plataforma embarcada *Intel Edison* durante o uso do algoritmo baseado em 1-NN e intervalo de 3 segundos, manteve os níveis de consumo, cuja potência média registrada gira em torno de 700 mW e picos em torno de 850 mW, conforme Figura 6.10 e quando não estavam executando o algoritmo, uma média de consumo em torno de 550 mW é verificada. O tempo total de avaliação encontrado foi cerca de 1200 segundos (20 minutos).

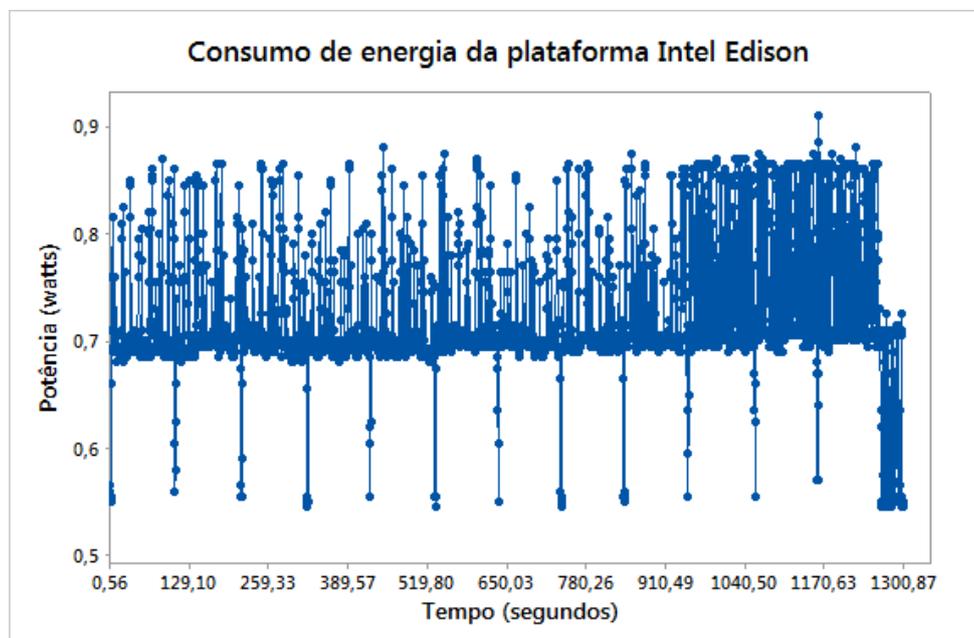
Os picos verificados nos gráficos representam o consumo de energia durante o processamento de cada imagem, que no intervalo dado retorna ao consumo nominal da plataforma, ou seja, sem a execução do algoritmo proposto. Os picos são mais evidentes utilizando o algoritmo *watershed* uma vez que o tempo de processamento é quase equivalente ao tempo de intervalo adotado. O algoritmo baseado em 1-NN possui tempo de processamento muito

Figura 6.9: Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo *watershed* na plataforma *Intel Edison*



Fonte: Próprio autor.

Figura 6.10: Variação do consumo de energia ao longo do processamento de imagens com uso do algoritmo 1-NN na plataforma *Intel Edison*



Fonte: Próprio autor.

superior ao intervalo configurado, mesmo assim é possível verificar por meio dos gráficos que os picos inferiores representam os intervalos de processamento entre as imagens e os picos superiores estão relacionados ao consumo energético máximo durante a execução do algoritmo. Os dados obtidos com as medições de consumo de energia em relação à potência média, mínima e máxima são detalhadas na Tabela 6.14.

Tabela 6.14: Consumo de energia (*em watts*) nos sistemas embarcados

Plataforma	<i>Watershed</i>			<i>1-NN</i>			Potência Média
	P_{media}	P_{min}	P_{max}	P_{media}	P_{min}	P_{max}	
<i>DE2i-150</i>	11,38	11,11	12,59	11,80	11,10	12,61	11,69
<i>Raspberry Pi 2</i>	1,42	1,28	1,66	1,32	1,11	1,53	1,37
<i>Intel Edison</i>	0,70	0,54	0,90	0,72	0,54	0,91	0,71

Observa-se uma leve variação de consumo de energia em relação ao tipo de algoritmo utilizado, perceptível no sistema embarcado baseado em ARM. O nível médio de potência registrado na plataforma *Raspberry Pi 2* foi reduzido aproximadamente 7% quando o algoritmo 1-NN foi executado. Ao contrário, as plataformas *Intel Edison* e *DE2i-150* registraram aumento da média de consumo elétrico em 2,75% e 3,6%, respectivamente. Os testes foram realizados em um mesmo ambiente e com os mesmos grupos de imagens.

Em relação aos sistemas embarcados avaliados, a plataforma *Intel Edison* possui a melhor eficiência energética. Os testes comprovam uma média de consumo em torno de 710 mW durante o processamento de imagens, o que representa 52% do consumo da plataforma *Raspberry Pi 2*. Por sua vez, a plataforma *Raspberry Pi 2* apresenta uma eficiência energética superior à plataforma *DE2i-150*, com valores de consumo de energia cerca de 88% mais baixos.

Em relação aos algoritmos avaliados nesta pesquisa, destacam-se as principais vantagens e desvantagens em cada uma das abordagens, conforme a Tabela 6.15.

Tabela 6.15: Análise comparativa dos algoritmos avaliados

<i>Características</i>	<i>Watershed</i>	1-NN
Nível de interferência humana	Elevada	Baixa
Tempo de processamento	Baixo	Elevado
Dependência de limiar	SIM	NÃO
Processamento com os canais RGB	NÃO	SIM
Redução dos efeitos da luminosidade	NÃO	SIM

6.4 Publicações aceitas e submetidas

Alguns resultados deste trabalho foram escritos no formato de artigo e submetidos a alguns congressos e anais de eventos, conforme a seguir.

- SILVA, J. F.; BRITO, A. V.; MOURA, H. N.; LIMA, J. A. G. "An Embedded System for Aerial Image Processing from Unmanned Aerial Vehicles". *In Brazilian Symposium on Computing Systems Engineering (SBESC)*. 2015. Foz do Iguaçu. Aceito e publicado.
- SILVA, J. F.; BRITO, A. V.; MOURA, H. N.; LIMA, J. A. G. "Identification of malformation in plantations through aerial images processing obtained by UAV". *Congresso Brasileiro de Agroinformática (SBIAGRO)*. 2015. Ponta Grossa, PR. Aceito e publicado.
- SILVA, J. F.; ASSIS, H. Y. E. G.; BRITO, A. V.; ALMEIDA, N. V. "VANT como ferramenta auxiliar na análise da cobertura e uso da terra." *Congresso Brasileiro de Agroinformática (SBIAGRO)*. 2015. Ponta Grossa, PR. Aceito e publicado
- BRITO, A.; FERNANDES, J.; NOGUEIRA, H.; ANTÔNIO, J. "Um sistema embarcado aplicado ao setor agrícola para o processamento de imagens aéreas obtidas por VANTs". *Simpósio Brasileiro de Computação Ubíqua e Pervasiva, 2015*. Recife, PE. Artigo enviado e não aceito.

Capítulo 7

Considerações Finais

Este trabalho apresentou dois algoritmos de processamento de imagens capazes de identificar áreas de solo exposto em uma vegetação, em que cada um apresenta suas peculiaridades. O primeiro método proposto faz uso de técnicas baseadas em *watershed* e, por utilizar etapas de limiarização, necessita da intervenção humana para definição de alguns parâmetros a cada vez que um grupo de imagens com características similares é processado. O segundo método utiliza uma abordagem baseada em aprendizagem de máquina, por meio da técnica de classificação baseada no 1-vizinho mais próximo que, após a seleção de um conjunto de dados de treinamento bem definida, dispensa a intervenção humana durante as etapas de segmentação. Além disso, o uso dos três canais do espaço de cores RGB e sua conversão para o espaço HSI tornam o sistema mais robusto ao passo que desprezam as variações de luminosidade presente nas imagens.

Considerando a qualidade da segmentação, dados de acurácia obtidos neste trabalho mostram resultados satisfatórios em ambos algoritmos utilizados. Aplicado ao setor agrícola, resultados da segmentação de imagens do plantio de cana de açúcar apresentam melhores resultados com uso do algoritmo baseado em 1-NN, segundo especialistas. Aplicado ao contexto ambiental, os resultados foram mais satisfatórios com uso do algoritmo baseado em *watershed*. Como não houve identificação dos métodos utilizados nas imagens enviadas aos especialistas, foram desconsideradas as vantagens de cada método durante a análise. Considerando a capacidade de realização de tarefas autônomas como requisitos para viabilizar a aplicação do sistema em tempo real, podemos concluir que a segmentação baseada no 1-vizinho mais próximo é mais eficiente.

Os algoritmos propostos neste trabalho foram capazes de funcionar em computadores de pequeno porte e baixo consumo. Em relação ao desempenho, os algoritmos apresentaram tempo de processamento aceitáveis, principalmente o algoritmo baseado em *watershed* que, devido a sua simplicidade computacional, apresentou tempo de processamento bastante inferior ao algoritmo baseado em 1-NN.

Em relação aos sistemas embarcados, a plataforma *Intel DE2i-150*, apesar do melhor desempenho observado e da variedade de interfaces de comunicação disponíveis, não é indicada para o sistema proposto devido as suas grandes dimensões e alto consumo de energia, tornando inviável a sua utilização acoplada a um VANT. O melhor desempenho entre as plataformas possíveis de ser acopladas a um VANT é observado na *Intel Edison*, que apresentou desempenho cerca de 20% superior à *Raspberry Pi 2*. Em relação à eficiência energética, a plataforma *Intel Edison* também é a mais eficiente. Apesar da plataforma *Intel Edison* apresentar melhores resultados de desempenho e eficiência energética, a plataforma *Raspberry Pi 2* apresenta resultados similares em alguns casos específicos, desta forma outras métricas do projeto podem ser consideradas.

Em geral, é possível concluir que as plataformas *Intel Edison* (x86) e *Raspberry Pi 2* (ARM) são dois possíveis computadores de pequeno porte que podem ser acoplados a um VANT e apresentam resultados satisfatórios em relação às principais métricas avaliadas neste trabalho. Considerando as características de hardware, a primeira apresenta vantagens como dimensões mais reduzidas, menor peso e menor consumo de energia, além de possuir comunicação sem fio. A plataforma *Raspberry Pi 2* possui vantagens como maior possibilidade de comunicação, facilidade na configuração por permitir sistemas operacionais com interface gráfica, além de flexibilidade para a inserção de novos dispositivos por meio de extensão GPIO, característica primordial para futura expansão das capacidades do VANT.

Considerando a aplicação de técnicas computacionais em trabalhos futuros que podem aumentar o desempenho do algoritmo 1-NN, a facilidade de configuração e sobretudo a possibilidade de agregar novas funcionalidades, este estudo conclui que a plataforma *Raspberry Pi 2* é o sistema embarcado mais apropriado, de acordo com as necessidades e possibilidades futuras do projeto. Além disso, esta plataforma associada ao uso de câmeras não-métricas garantem uma solução de baixo custo e eficiente para o processamento de imagens aéreas aplicados ao contexto agrícola ou ambiental.

7.1 Principais contribuições

A principal contribuição diz respeito à construção e adaptação de algoritmos baseados em técnicas simples de processamento de imagens, obtidas por câmeras não-métricas, e a capacidade de embarcá-los em plataformas de pequeno porte. Outras contribuições são apresentadas a seguir.

- Implementação e adaptação de algoritmos de processamento de imagens para a identificação de solo exposto.
- Desenvolvimento de uma solução aplicada ao problema real de avaliação dos níveis de degradação ambiental em áreas de preservação.
- Implementação de uma solução de baixo custo, que pode auxiliar pequenos e médios produtores por meio da solução acoplada a um VANT.
- Contribuição teórica e prática sobre a ampliação das capacidades de um VANT com foco em desenvolvimento de tarefas autônomas utilizando técnicas de aprendizagem de máquina.
- Estudo avaliativo de plataformas de pequeno porte e baixo consumo em relação ao desempenho e consumo de energia, servindo de referência para a comunidade científica.
- Divulgação na comunidade científica de resultados parciais deste trabalho acerca de métodos de processamento de imagens.
- Contribuição e troca de experiências com a comunidade acadêmica e empresas do setor de tecnologia agrícola, incentivando o desenvolvimento de soluções de baixo custo tornando-as mais acessíveis aos usuários.

7.2 Sugestões para Trabalhos Futuros

O sistema de processamento de imagens foi capaz de identificar falhas em plantações ou áreas de degradação ambiental, através da análise de solo exposto em uma imagem. Durante o percurso para atingir os objetivos deste trabalho, tornaram-se evidentes algumas propostas que são sugeridas como trabalhos futuros, apresentadas a seguir.

- Utilização de novos atributos de imagem visando melhorar a etapa de segmentação a partir da técnica do 1-vizinho mais próximo, como por exemplo, o uso de textura.
- Criação de novas classes para identificação de outras unidades de paisagem presentes em imagens ambientais, como, por exemplo, identificar a presença de corpos d'água na imagem, além de solo exposto.
- Melhorar o desempenho em relação ao tempo de processamento do algoritmo utilizando técnicas de computação paralela, por exemplo.
- Verificar a viabilidade de uso de um sistema baseado em FPGA acoplado para contribuir com os cálculos de processamento, minimizando o tempo de processamento.

Bibliografia

ABULEIL, A. M.; TAYLOR, G. W.; MOUSSA, M. An Integrated System for Mapping Red Clover Ground Cover Using Unmanned Aerial Vehicles: A Case Study in Precision Agriculture. *2015 12th Conference on Computer and Robot Vision*, p. 277–284, 2015.

AHMAD, A. et al. Digital Aerial Imagery of Unmanned Aerial Vehicle for Various Applications. In: *IEEE International Conference on Control System, Computing and Engineering*. Penang, Malaysia: [s.n.], 2013. p. 535–540.

ALKOFFASH, M. S. et al. A Survey of Digital Image Processing Techniques in Character Recognition. *International Journal of Computer Science and Network Security*, v. 14, n. 3, p. 65–71, 2014.

ALVES, M. O.; FERREIRA, R. V.; GALLIS, R. B. d. A. Otimização da Identificação de Falhas de Plantio na Cana-de-Açúcar com Uso de Geoprocessamento. In: *Congresso Brasileiro de Agroinformática (SBIAGRO 2015)*. Ponta Grossa, PR: [s.n.], 2015.

AMORIM, L. A. et al. Estimação de Posição e Atitude de um Veículo Aéreo Não Tripulado baseada em GPS, IMU e Dados Visuais. In: *XII Simpósio Brasileiro de Automação Inteligente (SBAI)*. Natal-RN: [s.n.], 2015.

ANTONIO, F. et al. How Sustainable Is The Use of Natural Resources in Brazil ? *Brazilian Journal of Nature Conservation*, v. 10, n. July, p. 77–82, 2012.

ASSIS, H. Y. E. G. de; ALMEIDA, N. V.; SANTOS, A. A. dos. Mapeamento das Unidades de Paisagem da Área de Proteção Ambiental da Barra do rio Mamanguape - PB. *XXVI Congresso Brasileiro de Cartografia*, 2014.

BALA, A. An Improved Watershed Image Segmentation Technique using MATLAB. *International Journal of Scientific & Engineering Research*, v. 3, n. 6, p. 1–4, 2012.

BARRETTO, A. G. O. P. et al. Agricultural intensification in Brazil and its effects on land-use patterns: an analysis of the 1975-2006 period. *Global change biology*, v. 19, n. 6, p. 1804–15, jun 2013.

BERNI, J. et al. Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring From an Unmanned Aerial Vehicle. *Geoscience and Remote Sensing, IEEE Transactions on*, v. 47, n. 3, p. 722–738, 2009.

BEUCHER, S.; LANTUEJOUL, C. Use of Watersheds in Contour Detection. In: *International Workshop on Image Processing: Real-time Edge and Motion Detection/Estimation*. Fontainebleau: [s.n.], 1979. p. 12–21.

- BHATIA, N.; VANDANA. Survey of Nearest Neighbor Techniques. *International Journal of Computer Science and Information Security*, v. 8, n. 2, p. 4, 2010.
- BIENIECKI, W. Oversegmentation avoidance in watershed-based algorithms for color images. *Proceedings of the International Conference Modern Problems of Radio Engineering, Telecommunications and Computer Science, 2004.*, 2004.
- BIENIEK, A.; MOGA, A. An efficient watershed algorithm based on connected components. *Pattern Recognition*, v. 33, p. 907–916, 2000.
- BLEAU, A.; LEON, L. Watershed-Based Segmentation and Region Merging. *Computer Vision and Image Understanding*, v. 77, n. 3, p. 317–370, mar 2000.
- BLOM, J. D. *Unmanned Aerial Systems : A Historical Perspective*. [S.l.]: Combat Studies Institute Press. US Army Combined Arms Center. Fort Leavenworth, Kansas, 2010. 140 p. ISBN 9780982328309.
- BLOTTA, E. et al. Enhancement of medical images in HSI color space. *Journal of Physics: Conference Series*, v. 332, p. 012041, 2011.
- BONIECKI, P. et al. Neural identification of selected apple pests. *Computers and Electronics in Agriculture*, Elsevier B.V., v. 110, p. 9–16, jan 2015.
- BORGEFORS, G. Distance transformations in digital images. *Computer Vision, Graphics, and Image Processing*, v. 34, n. 3, p. 344–371, 1986.
- BRADSKI, G.; KAEHLER, A. *Learning OpenCV*. First edit. [S.l.: s.n.], 2008. ISBN 9780596516130.
- BRITO, J. N.; COELHO, L. *Fotogrametria Digital*. 1.ª ed. Rio de Janeiro: Instituto Militar de Engenharia, 2002.
- CAMPOY, P. et al. Computer Vision Onboard UAVs for Civilian Tasks. *Journal of Intelligent and Robotic Systems*, v. 54, n. 1-3, p. 105–135, aug 2009. ISSN 0921-0296.
- CATSOUKLIS, J. *Designing Embedded Hardware*. 2. ed. Sebastopol, CA, USA: O'Reilly Media, 2005. ISBN 0-596-00755-8.
- CHÁVEZ, E. et al. Near neighbor searching with K nearest references. *Information Systems*, Elsevier, v. 51, p. 43–61, feb 2015.
- CLARKE, T. A.; FRYER, J. F. The development of camera calibration methods and models Photogrammetric Record. *Photogrammetric Record*, v. 16, p. 51–66, 1998.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS), v. 92, p. 79–97, jun 2014.
- CONNER, M.; DUNBAR, D. *Armstrong Photo Gallery - Current Aircraft, Projects, and Programs 2005 - 2015*. 2002. Disponível em: <<http://www.nasa.gov/centers/armstrong/multimedia/imagegallery/index.html>>. Acesso em: 01 de agosto de 2015.

CÔRTEZ, J. B. R. *Análise da estabilidade geométrica de câmaras digitais de baixo custo com diferentes métodos de calibração*. 144 p. Tese (Tese de Doutorado) — UFP, Curitiba, 2010.

COVER, T.; HART, P. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, v. 13, n. 1, p. 21–27, 1967. ISSN 0018-9448.

DENG, Z.; MA, C.; ZHU, M. A reconfigurable flight control system architecture for small unmanned aerial vehicles. In: *Systems Conference (SysCon), 2012 IEEE International*. [S.l.: s.n.], 2012. p. 1–4.

DRIESSENS, K. et al. Using Weighted Nearest Neighbor to Benefit from Unlabeled Data. In *Advances in Knowledge Discovery and Data Mining*, p. 60–69, 2006. ISSN 0302-9743.

DRUBIN, C. The Global UAV Market 2015-2025. *Microwave Journal*, Horizon House Publications Inc., v. 58, n. 3, p. 53–54, mar 2015.

EHSANI, R.; MAJA, J. M. The rise of small UAVs in precision agriculture. *Resource: Engineering & Technology for a Sustainable World*, v. 20, p. 18+, jun 2013.

FACELI, K. et al. *Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina*. 1. ed. Rio de Janeiro: LTC, 2011.

FELIZARDO, L. F. et al. Using ANN and UAV for terrain surveillance. In: *13th International Conference on Hybrid Intelligent Systems (HIS 2013)*. Yasmine Hammamet, Tunísia: Ieee, 2013. p. 1–5.

FILIPE, M.; GON, S. Classification of Vegetation Types in Military Region. 2014.

FORSYTH, D.; PONCE, J. *Computer Vision: A Modern Approach*. [S.l.]: Pearson, 2012. (Always learning). ISBN 9780136085928.

FRANCO, E. S.; LIRA, V. M. D. Uso de Imagens TM / LANDSAT-5 na Identificação de Degradação Ambiental na Microbacia Hidrográfica em Boqueirão, PB. p. 79–88, 2007.

GILLIES, D. *Internet FAQ Archives - Realtime: Frequently Asked Questions (FAQs)*. 1998. Disponível em: <<http://www.faqs.org/faqs/realtime-computing/faq/>>. Acesso em: 01 de agosto de 2015.

GONZÁLEZ-ESPASANDÍN, Ó.; LEO, T. J.; NAVARRO-ARÉVALO, E. Fuel cells: a real option for Unmanned Aerial Vehicles propulsion. *TheScientificWorldJournal*, v. 2014, p. 497642, jan 2014.

GONZALEZ, R. C.; WOODS, R. C. *Processamento Digital de Imagens*. 3. ed. São Paulo: Pearson Prentice Hal, 2007.

HABIB, A. et al. Standards and Specifications for the Calibration and Stability of Amateur Digital Cameras for Close-range Mapping Applications. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences.*, Beijing, XXXVII, p. 1059–1064, 2008.

- HERWITZ, S. et al. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. *Computers and Electronics in Agriculture*, v. 44, n. 1, p. 49–61, jul 2004.
- ICAO. *Global Air Traffic Management Operational Concept - Doc 9854 AN/458*. Montreal, 2005. 82 p.
- JORGE, L. A. C.; BRANDÃO, Z. N.; INAMASU, R. Y. Insights and recommendations of use of UAV platforms in precision agriculture in Brazil. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XVI*, v. 9239, n. 2004, p. 923911, 2014.
- Jr. Santos, R. d. L.; MITISHITA, E. A.; MACHADO, A. M. L. Calibration of digital cameras with an interval of one year. *I Simpósio em Ciências Geodésicas e Tecnologias da Geoinformação*, Recife, n. Ccd, 2004.
- JÚNIOR, A. L. et al. Estimativa da fração coberta do solo em canavial usando imagens aéreas obtidas por Vants . In: *Congresso Brasileiro de Agroinformática (SBIAGRO)* . Ponta Grossa, PR: [s.n.], 2015.
- JUNIOR, J. M. et al. Atualização e geração de produtos cartográficos a partir de imagens obtidas com câmaras analógica e digital. In: *XIV Simpósio Brasileiro de Sensoriamento Remoto*. Natal-RN: [s.n.], 2009. p. 1803–1810.
- JÚNIOR, L. R. A.; CÔRTEZ, J. B. R.; FERREIRA, M. E. Validation of Mosaics Aerophotogrammetric Using Photographs Obtained From Digital Camera Not Measure Attached To a UAV. *XXVI Congresso Brasileiro de Cartografia*, p. 1–15, 2014.
- JÚNIOR, L. R. A. et al. Validação de ortomosaicos e Modelos Digitais de Superfície utilizando fotografias obtidas com câmera digital não métrica acoplada a um VANT. *XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, João Pessoa-PB, p. 2157–2164, 2015.
- KONTITSIS, M.; VALAVANIS, K. P.; TSOURVELOUDIS, N. A UAV Vision System for Airborne Surveillance. In: *International Conference on Robotics & Automation*. New Orleans, LA, Estados Unidos: [s.n.], 2004. p. 77–83.
- KOOPMAN, P. Embedded System Design Issues (the Rest of the Story) Philip. In: . Austin, TX: Proceedings of the International Conference on Computer Design, 1996. p. 310–317.
- LEE, E. a. Embedded software. *Advances in Computers*, v. 56, n. C, p. 55–95, 2002.
- LEONEL, C. *Inpa utiliza drone para obter dados para inventários florestais na Amazônia*. 2014. Disponível em: <<http://portal.inpa.gov.br/index.php/ultimas-noticias/419-inpa-utiliza-drone-para-obter-dados-para-inventarios-florestais-na-amazonia>>.
- LEWIS, D.; PHINN, S.; ARROYO, L. Cost-Effectiveness of Seven Approaches to Map Vegetation Communities: A Case Study from Northern Australia Tropical Savannas. *Remote Sensing*, v. 5, n. 1, p. 377–414, 2013.
- LI, N. et al. Unsupervised polarimetric synthetic aperture radar classification of large-scale landslides caused by Wenchuan earthquake in hue-saturation-intensity color space. *Journal of Applied Remote Sensing*, v. 8, n. 1, p. 083595, 2014.

- LIM, Y. W.; LEE, S. U. On the color image segmentation algorithm based on the thresholding and the fuzzy c-means techniques. *Pattern Recognition*, v. 23, n. 9, p. 935–952, 1990.
- LIU, Y.-C.; DAI, Q.-H. A Survey of Computer Vision Applied in Aerial Robotic Vehicles. In: *Optics Photonics and Energy Engineering (OPEE)*. Wuhan, China: [s.n.], 2010. p. 277–280.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. *Identificação de Ruídos em Dados de Bioinformática*. São Carlos, SP, 2007.
- LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, v. 60, n. 2, p. 91–110, 2004.
- MALEK, S. et al. Efficient Framework for Palm Tree Detection in UAV Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 12, p. 4692–4703, 2014.
- MANJUNATH, B. S. et al. Color and texture descriptors. *IEEE Transactions on Circuits and Systems for Video Technology*, v. 11, n. 6, p. 703–715, 2001.
- MEDEIROS, F. A. *Desenvolvimento de um veículo aéreo não tripulado para aplicação em agricultura de precisão*. Tese (Dissertação de Mestrado) — Universidade Federal de Santa Maria, 2007.
- MEDEIROS, N. D. G. *Segmentação morfológica aplicada à cartografia*. 131 p. Tese (Dissertação de mestrado) — Universidade Estadual Paulista, 2003.
- MENDONÇA, J. C. et al. Mapeamento das áreas de cana-de-açúcar na região Norte Fluminense - RJ por uso de técnicas de sensoriamento remoto. *Engenharia Agrícola*, v. 31, p. 561–571, 2011.
- MEYER, F. Topographic distance and watershed lines. *Signal Processing*, v. 38, n. 1, p. 113–125, 1994.
- MITISHITA, E. et al. O uso de Veículos Aéreos Não Tripulados (Vants) em Aplicações de Mapeamento Aerofotogramétrico. *XXVI Congresso Brasileiro de Cartografia*, 2014.
- MOREIRA, M. A. *Fundamentos do Sensoriamento Remoto e metodologias de aplicação*. 3.ª ed. Viçosa: Universidade Federal de Viçosa, 2003.
- MOROZ, M. R.; JASINSKI, R. P.; PEDRONI, V. A. Requirements for Embedded Operating Systems Adoption. *Visión Electrónica Ano 5 No. 2*, n. 2, p. 90–97, 2012.
- MOTA, R. L. et al. Expanding Small UAV Capabilities with ANN. In: *Second International Conference on Image Information Processing (ICIIP-2013)*. Himachal Pradesh, Índia: [s.n.], 2013. p. 516–520.
- NASCIMENTO, M. C. et al. Use of ASTER sensor images for the identification of levels of pasture degradation. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, PB, v. 10, n. 82, p. 196–202, 2006.

- NETO, J. et al. A surveillance task for a uav in a natural disaster scenario. In: *Industrial Electronics (ISIE), 2012 IEEE International Symposium on*. [S.l.: s.n.], 2012. p. 1516–1522. ISSN 2163-5137.
- OLIVEIRA, R. A. D. et al. Avaliação do Corregistro de Imagens coletadas por uma Câmara Hiperespectral de Quadro. *XXVI Congresso Brasileiro de Cartografia*, 2014.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de Imagens Digitais*. São Paulo: [s.n.], 2007. ISBN 978-85-221-0595-3.
- PIMENTEL, G. F. *Curso de estatística experimental*. 14. ed. Piracicaba: [s.n.], 2000. 477 p.
- PING, J. T. K. et al. Generic Unmanned Aerial Vehicle (UAV) for civilian application. In: *IEEE Conference on Sustainable Utilization and Development in Engineering and Technology*. Kuala Lumpur, Malaysia: [s.n.], 2012. p. 289–294.
- PITAS, I. *Digital Image Processing Algorithms and Applications*. [S.l.]: Wiley, 2000. (AWiley-Interscience publication). ISBN 9780471377399.
- REZENDE, S. O. *Sistemas Inteligentes: Fundamentos e Aplicações*. [S.l.]: Manole, 2003. ISBN 9788520416839.
- ROSIN, P. L.; IOANNIDIS, E. Evaluation of global image thresholding for change detection. *Pattern Recognition Letters*, v. 24, n. 14, p. 2345–2356, oct 2003.
- RUSS, J. C. *The Image Processing Handbook, Seventh Edition*. [S.l.]: CRC Press, 2016. ISBN 9781498740289.
- RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3rd. ed. Upper Saddle River, NJ, USA: Prentice Hall Press, 2009. ISBN 0136042597, 9780136042594.
- SAHA, S.; BASU, S.; NASIPURI, M. A Comprehensive Survey on Different Techniques and Applications of Digital Image Processing. *Proc. of Int. Conf. on Computing, Communication & Manufacturing*, p. 75–87, 2014.
- SALCIC, Z.; RADOJEVIC, I. *Embedded Systems Design Based on Formal Models of Computation*. New York, USA: Springer, 2011. 200 p.
- SALERI, R. et al. UAV Photogrammetry for archaeological survey : The Theaters area of Pompeii. p. 497–502, 2013.
- SHIMIZU, M. S. Implementação de um Controlador Lógico Programável (CLP) utilizando um Field-Programmable Gate Array (fpga) como núcleo de processamento. *Instituto de Estudos Superiores da Amazônia*, 2012.
- SILVA, J. F. et al. VANT como ferramenta auxiliar na análise da cobertura e uso da terra. In: *Congresso Brasileiro de Agroinformática*. Ponta Grossa, PR: [s.n.], 2015.
- SILVA, J. F. et al. An Embedded System for Aerial Image Processing from Unmanned Aerial Vehicles. In: *Brazilian Symposium on Computing Systems Engineering (SBESC)*. Foz do Iguaçu.: [s.n.], 2015.

- STALLINGS, W. *Computer Organization and Architecture*. 8. ed. [S.l.: s.n.], 2010.
- SUSSTRUNK, S.; BUCKLEY, R.; SWEN, S. *Standard RGB color spaces*. [S.l.], 1999. 1–47 p. Disponível em: <<http://www.ingentaconnect.com/content/ist/cic/1999/00001999/00000001/art00024>>.
- TAN, S.-L.; ANH, T. N. B. Real-time operating system (RTOS) for small (16-bit) microcontroller. *2009 IEEE 13th International Symposium on Consumer Electronics*, Ieee, p. 1007–1011, 2009.
- TAURION, C. *Software embarcado: oportunidades e potenciais de mercado*. Rio de Janeiro: Brasport, 2005. ISBN 85-7452-228-7.
- Trindade Jr., O. et al. A Mission Planner and Navigation System. *23rd ICAS - Congress of International Council of the Aeronautical Sciences*, Toronto, Canada, p. 682.1 – 682.8, 2002.
- UPTON, E.; HALFACREE, G. *Raspberry Pi Manual do Usuário*. São Paulo: [s.n.], 2013.
- URBAHS, A.; JONAITE, I. Features of the use of unmanned aerial vehicles for agriculture applications. *Aviation*, v. 17, p. 170–175, 2013.
- UTO, K. et al. Characterization of Rice Paddies by a UAV-Mounted Miniature Hyperspectral Sensor System. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 6, n. 2, p. 851–860, 2013.
- WANGENHEIM, A. V.; SANTOS, C. A. dos; SOUZA, A. I. de. Morfologia matemática. In: *Introdução à Visão Computacional*. Santa Catarina: [s.n.], 1998. cap. 3, p. 50–80.
- WEKA. *Weka 3: Data Mining Software in Java*. 2015. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/index.html>>. Acesso em: 17 de janeiro de 2016.
- YAGHMOUR, K. et al. *Building Embedded Linux Systems*. Second edi. [S.l.: s.n.], 2008. ISBN 9780596529680.
- YANHUI, X. et al. Color Distortion of Digital Image and its Detection. *TELKOMNIKA Indonesian Journal of Electrical Engineering*, v. 11, n. 8, p. 4565–4571, 2013.
- ZARBIN, P. H. G.; RODRIGUES, M. A. C. M. Feromônios de insetos: Tecnologia e desafios para uma agricultura competitiva no Brasil. *Quim. Nova*, v. 32, n. 3, p. 722–731, 2009.
- ZHANG, P. Model Selection Via Multifold Cross Validation. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 21, n. 1, p. 299–313, 1993.