

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

Uma solução para Análise de Vegetação, Separação e
Localização de Zonas de Manejo em Imagens Aéreas
Utilizando Sistemas com Baixo Poder de Processamento.

Suzane Gomes dos Santos

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: Ciências da Computação
Linha de Pesquisa: Sinais, Sistemas Digitais e Gráficos

Dr. Alisson V. Brito
(Orientador)

João Pessoa, Paraíba, Brasil

©Suzane Gomes dos Santos, 31 de Janeiro de 2020

Catálogo na publicação
Seção de Catalogação e Classificação

S237s Santos, Suzane Gomes Dos.

Uma solução para Análise de Vegetação, Separação e
Localização de Zonas de Manejo em Imagens Aéreas
Utilizando Sistemas com Baixo Poder de Processamento. /
Suzane Gomes Dos Santos. - João Pessoa, 2020.
66 f. : il.


Orientação: Alisson Brito.
Dissertação (Mestrado) - UFPB/CI.

1. Processamento de Imagem. 2. Sistema Embarcado. 3.
VANT. 4. NDVI. 5. K-means. I. Brito, Alisson. II.
Título.

UFPB/BC



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



Ata da Sessão Pública de Defesa de Dissertação de Mestrado de Suzane Gomes dos Santos, candidata ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 31 de janeiro de 2020.




1 Aos trinta e um dias do mês de janeiro, do ano de dois mil e vinte, às nove horas, no Centro
2 de Informática da Universidade Federal da Paraíba, em Mangabeira, reuniram-se os
3 membros da Banca Examinadora constituída para julgar o Trabalho Final da Sra. Suzane
4 Gomes dos Santos, vinculado a esta Universidade sob a matrícula nº 20181000706,
5 candidato ao grau de Mestre em Informática, na área de "Sistemas de Computação", na linha
6 de pesquisa "Sinais, Sistemas Digitais e Gráficos", do Programa de Pós-Graduação em
7 Informática, da Universidade Federal da Paraíba. A comissão examinadora foi composta
8 pelos professores: Alisson Vasconcelos de Brito (PPGI-UFPB), Orientador e Presidente da
9 Banca, Thais Gaudêncio do Rego (PPGI-UFPB), Examinadora Interna, Francisco Petrônio
10 Alencar de Medeiros (IFPB), Examinador Externo à Instituição. Dando início aos trabalhos, o
11 Presidente da Banca cumprimentou os presentes, comunicou aos mesmos a finalidade da
12 reunião e passou a palavra ao candidato para que o mesmo fizesse a exposição oral do
13 trabalho de dissertação intitulado: "Uma solução para Análise de Vegetação, Separação e
14 Localização de Zonas de Manejo em Imagens Aéreas Utilizando Sistemas com Baixo Poder
15 de Processamento". Concluída a exposição, a candidata foi arguida pela Banca
16 Examinadora que emitiu o seguinte parecer: "**aprovado**". Do ocorrido, eu, Ruy Alberto Pisani
17 Altafim, Coordenador do Programa de Pós-Graduação em Informática, lavrei a presente ata
18 que vai assinada por mim e pelos membros da banca examinadora. João Pessoa, 31 de
19 janeiro de 2020.


Prof. Dr. Ruy Alberto Pisani Altafim

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

Profª. Thais Gaudêncio do Rego
Examinadora Interna (PPGI-UFPB)

Prof. Francisco Petrônio Alencar de Medeiros
Examinador Externo à Instituição (IFPB)

.

Dedico este trabalho aos meus maiores incentivadores: Melinda, Josivânia e Anderson.

Agradecimentos

Agradeço, em primeiro lugar, a Deus por estar sempre comigo. À minha mãe, por sempre batalhar para me dar tudo o que eu precisava, sempre me aconselhar, incentivar e apoiar nas minhas decisões.

À minha filha, que me desafiou a continuar dando o melhor de mim durante todo o mestrado, sempre me dando alegria, me motivando e me ensinando a ser uma pessoa melhor. Ao meu esposo, que sempre me apoiou nos meus estudos e decisões, mesmo quando não concordava. E por estar sempre ao meu lado me ajudando, dando suporte, sendo um pai e um esposo presente e meu revisor pessoal.

Aos meus amigos de laboratório e de jornada que, de uma forma ou de outra, contribuíram na minha formação. Principalmente à Joana, por nunca medir esforços para me ajudar quando precisava e, também, por me fornecer as imagens capturadas pelo VANT e ao meu amigo Alexandre, por me ajudar na captura das imagens em solo.

Também agradeço a todos os professores, que compartilharam o seus conhecimentos comigo. Em especial ao meu orientador Alisson, por sempre me ajudar, aconselhar, orientar e incentivar.

.

"Só se vê bem com o coração, o essencial é invisível aos olhos."
(Antoine de Saint-Exupéry).

Resumo

O uso de tecnologias modernas, como sensores, plataformas de monitoramento portáteis e Veículos Aéreos Não Tripulados (VANTs), na Agricultura de Precisão, tem trazido grandes contribuições no processo de desenvolvimento agrônomo, por promover acompanhamento de campos de forma mais precisa e detectar problemas na vegetação em tempo quase real de forma não intrusiva, com baixo consumo de tempo e custo. Este trabalho apresenta um sistema automático para monitoramento de vegetação e separação em zonas de manejo utilizando imagens aéreas capturadas por VANTs. Para isto, utiliza o Índice de Vegetação por Diferença Normalizada (NDVI) e o algoritmo de clusterização *K-means*. O sistema também permite localizar cada zona por meio de sua coordenada geográfica. O algoritmo foi otimizado, permitindo sua execução em sistemas embarcados. Como resultado, tempos de processamento de aproximadamente 6 segundos foram alcançados para uma imagem com 9.387.360 pixels usando um computador convencional, e 0,54 segundos para uma imagem de 870.400 pixels usando um sistema embarcado.

Palavras-chave: Processamento de Imagem, Sistema Embarcado, VANT, NDVI, K-means.

Abstract

The use of modern technologies, such as sensors, portable monitoring platforms and Unmanned Aerial Vehicles (UAVs), in Precision Agriculture, has brought great contributions to the agronomic development process, by a more accurate field monitoring and detecting vegetation issues in almost real time in a non-intrusive way, with low cost and time consumption. This work presents an automatic system of vegetation monitoring and separation in management zones using aerial images captured by Unmanned Aerial Vehicles (UAVs). The system analyzes crop images and divides them into regions identified by colors for easy visualization of problematic areas. To do so, it uses the Normalized Difference Vegetation Index (NDVI) and the K-means clustering algorithm. Besides, the system allows locating each management zone through geographical coordinates. The algorithm was optimized, allowing its execution in embedded systems. As result, processing times of approximately 6 seconds were achieved for an image with 9,387,360 pixels using a conventional computer, and 0.54 seconds for an image of 870,400 pixels using an embedded system.

Keywords: Image Processing, Embedded System, UAV, NDVI, K-means.

Conteúdo

1	Introdução	1
1.1	Contextualização	1
1.2	Objetivos	3
1.2.1	Objetivo Geral	3
1.2.2	Objetivos Específicos	3
1.3	Estrutura da Dissertação	3
2	Fundamentação Teórica	4
2.1	Agricultura de precisão e zonas de manejo	4
2.2	Fotossíntese e Índice de Vegetação por Diferença Normalizada (NDVI) . .	6
2.3	Pré-processamento de imagens	8
2.3.1	Filtragem de ruídos	8
2.3.2	Equalização	9
2.4	Algoritmo <i>K-means</i> para Segmentação de Imagem	10
2.5	Transformação de coordenadas de pixel em coordenadas geográficas	11
3	Trabalhos Relacionados	13
4	Metodologia	17
4.1	Captura e preparação das imagens aéreas	17
4.2	Otimização do cálculo do NDVI	20
4.2.1	Otimização do <i>K-means</i>	21
4.2.2	Desenvolvimento do sistema portátil, captura e processamento de imagens em solo	22
4.3	Sistemas de segmentação de zonas de manejo e de análise de imagens em solo.	25

4.3.1	Sistema de captura de coordenadas	27
5	Resultados e Discussões	29
5.1	Sistema aéreo - Estudo de caso	29
5.1.1	Desempenho	31
5.1.2	Sistema de captura de coordenadas	33
5.2	Sistema portátil - Estudo de caso	34
5.2.1	Cenário	36
5.2.2	Captura de imagens	37
5.2.3	Resultados	37
5.2.4	Discussões	41
5.3	Aplicações	44
6	Considerações finais	46
	Bibliografia	51

Lista de Símbolos

GGC : *Grupo de Grandes Culturas*

GIS : *Geographic Information System (Sistema de Informação Geográfica)*

GPS : *Global Positioning System (Sistema de Posicionamento Global)*

ha : *Hectare*

LAI : *Leaf Area Index (Índice de Área Foliar)*

NDVI : *Normalized Difference Vegetation Index (Índice de Vegetação por Diferença Normalizada)*

NGB : *Nir, Green, Blue (Infravermelho Próximo, Verde, Azul)*

NIR : *Near Infrared (Infravermelho Próximo)*

OMIS : *Operational Modular Imaging Spectrometer (Espectrômetro de Imagens Modulares Operacionais)*

PA : *Precision Agriculture (Agricultura de Precisão)*

PDI : *Processamento Digital de Imagens*

RGB : *Red, Green and Blue (Vermelho, Verde e Azul)*

SC-KM : *Spatial Contiguous K-Means (Espacial Contíguo K-means)*

TIFF : *Tagged Image File Format (Formato de Arquivo de Imagem com Tag)*

VANT : *Veículo Aéreo Não Tripulado*

VI : *Vegetation Index (Índice de Vegetação)*

VIS : *Visible Spectrum (Espectro Visível)*

WGS : *World Geodetic System (Sistema Geodésico Mundial)*

Lista de Figuras

2.1	(A) Processo de absorção de luz visível e reflexão de luz IR durante a fotossíntese. Adaptada de: (NASA, 2016); (B) Refletância espectral de planta saudável, planta doente e solo nos comprimentos de onda visível e NIR. Adaptada de: (CHANG et al., 2013).	6
2.2	Exemplo do resultado do NDVI em uma planta saudável à esquerda e uma doente à direita utilizando a equação $NDVI = \frac{(NIR-VIS)}{(NIR+VIS)}$. Adaptada de: (WIKIMEDIA, 2009).	8
2.3	(A) Vizinhança 3x3; (B) Ordenação do conjunto de valores da vizinhança e determinação da mediana (cor verde) e (C) Substituição do valor do pixel central pela mediana.	9
2.4	(A) Imagem original com baixo contraste e seu histograma; (B) Imagem após processo de equalização e seu histograma apresentando um aumento do contraste. Fonte: (OPENCV, 2015).	10
2.5	Organização de um arquivo raster onde cada célula tem sua posição definida pelos seus valores de linha e coluna. Adaptada de: (ARQGIS, 2016).	11
2.6	Fluxograma do funcionamento da transformação de coordenadas de pixel em latitude e longitude.	12
4.1	(A) Gráfico do filtro <i>Storaro Blue</i> , cuja função é garantir uma maior captura pela câmera dos comprimentos de onda azul (entre 440 e 480 nm) e infravermelho próximo (entre 740 e 950 nm). Adaptada de: (MASSANO, 2018).	18
4.2	Filtro <i>Storaro Blue</i> junto à câmera Pi NoIR.	18
4.3	Algumas imagens capturadas pelo VANT durante o voo.	19

4.4	(A) Mosaico criado no software OpenDroneMap; (B) Mosaico recortado mantendo apenas a região de interesse.	19
4.5	(A) Sistema portátil internamente apresentando todos os seus componentes; (B) Folha de papel usada para efetuar o balanço de branco na câmera. . . .	23
4.6	Interface gráfica do sistema portátil.	23
4.7	Mapa de cores utilizado no sistema. Fonte: (MATPLOTLIB, 2018)	25
4.8	Fluxograma do funcionamento do algoritmo de delimitação e geolocalização de zonas de manejo no sistema aéreo a partir do NDVI.	25
4.9	Fluxograma do funcionamento do sistema portátil.	26
4.10	(A) Ortomosaico de entrada do sistema aéreo, para este estudo; (B) Ortomosaico após o cálculo do NDVI e aplicação do mapa de cores.	26
4.11	(A) Ortomosaico no formato TIFF usado na captura de coordenadas; (B) Ortomosaico com zonas de manejo demarcadas usado para demarcar pontos de interesse.	28
5.1	(A) Ortomosaico da plantação de cana-de-açúcar analisada (B) Imagem NDVI com filtro da mediana e vizinhança de 55x55, (C) Imagem (B) equalizada apresentando uma separação bem delimitada dos valores de NDVI através dos diferentes tons de cinza.	30
5.2	(A) Resultado de referência, (B) Imagem segmentada pelo algoritmo <i>K-means</i> tradicional e (C) Imagem segmentada pelo algoritmo <i>K-means</i> aplicado ao histograma.	30
5.3	Diferentes configurações de zoom realizadas na imagem de entrada (A), (B) e (). Nas imagens o tamanho da tela é o mesmo, mudando apenas o zoom e a movimentação da imagem.	33
5.4	(A) Demarcação dos pontos 1,2,3 e 4 no sistema desenvolvido; (B) Demarcação dos pontos 1,2,3 e 4 no software QGIS.	34
5.5	(A) Tela apresentando a captura e análise da imagem pelo sistema, (B) Imagem capturada, (C) Resultado obtido com um filtro de vizinhança tamanho 35x35.	35

5.6	Imagem de satélite mostrando as localizações dos talhões 73 e 64, onde foram capturadas imagens para testar o sistema embarcado.	37
5.7	(A) e (C) Imagens do talhão 73; (B) e (D) Resultados NDVI apresentando um predomínio da cor verde.	42
5.8	(A) e (C) Imagens NDVI do talhão 73; (B) e (D) Histograma dos valores NDVI dos recortes das imagens (A) e (C), indicados pelo retângulo preto, apresentando maior prevalência de valores acima de 0,2 demonstrando maior vigor da plantação.	42
5.9	(A) e (C) Imagens do talhão 64; (B) e (D) Resultados NDVI apresentando um predomínio das cores laranja e vermelha.	43
5.10	(A) e (C) Resultados NDVI do talhão 64; (B) e (D) Histograma de cores dos valores NDVI dos recortes das imagens (A) e (C), indicados pelos retângulos pretos, apresentando maior prevalência de valores abaixo de 0.2, faixa de cores vermelho a amarelo, demonstrando menor vigor da plantação.	43
5.11	(A) Mosaico da área monitorada, (B) Imagem segmentada pelo algoritmo <i>K-means</i> separando em áreas de acordo com o vigor da plantação.	44
5.12	(A) Imagem da vegetação capturada, (C) Resultado NDVI apresentando baixo vigor da plantação em decorrência da carência de água.	45

Lista de Tabelas

3.1	Comparação das principais contribuições dos trabalhos relacionados juntamente com o proposto.	16
5.1	Comparação do tempo de processamento (em segundos) de uma imagem de 3280 x 2862 pixels (largura x altura) com diferentes configurações do sistema.	31
5.2	Comparação da máquina utilizada em (SILVA et al., 2017) com a deste estudo.	32
5.3	Saídas obtidas para cada ponto demarcado no sistema desenvolvido e no software QGIS, mostrando a semelhança nos resultados obtidos em ambos os sistemas.	34
5.4	Comparação dos resultados de tempo de processamento (em segundos) obtidos ao processar a Figura 5.5 com 700 x 705 pixels (largura x altura) nas placas Tinker e Raspberry PI.	36
5.5	Resultados obtidos efetuando o balanço de branco em papel azul.	38
5.6	Resultados obtidos efetuando o balanço de branco em papel branco.	39

Capítulo 1

Introdução

Neste capítulo o problema é contextualizado e são apresentados a relevância do trabalho desenvolvido, os objetivos e a estrutura geral do trabalho.

1.1 Contextualização

O uso crescente de tecnologias modernas na Agricultura de Precisão, do inglês *Precision Agriculture* (PA), tem trazido grandes contribuições no processo de desenvolvimento agrônômico, por promover práticas de gestão de variáveis e acompanhamento de campos de forma mais precisa (SEELAN et al., 2003; MORIYA et al., 2017). As mais tradicionais e ainda usadas plataformas de monitoramento de culturas são baseadas em análise de imagens capturadas por satélites (KAIVOSOJA et al., 2013) e plataformas de sensoriamento em solo, permitindo descobrir problemas e possibilitando manejá-los apropriadamente (WANG et al., 2002; DEVADAS et al., 2009; JIN et al., 2013). Entretanto, elas são limitadas pelo seu alto custo em grandes plantações, alto consumo de tempo, cobertura de nuvens, possibilidade de erro humano e de causar danos à vegetação (JIN et al., 2017; KAIVOSOJA et al., 2013; MORIYA et al., 2017).

Enquanto isso, o avanço da produção de sensores portáteis de baixo custo e o desenvolvimento de algoritmos de visão computacional permitiram transformar os Veículos Aéreos Não Tripulados (VANTs) em plataformas de sensoriamento remoto capazes de estimar a densidade de plantas e detectar problemas na vegetação em tempo quase real (ZHANG; KOVACS, 2012) através de métodos não intrusivos, com custo e consumo de tempo ainda mais

baixos do que as tecnologias de monitoramento mencionadas anteriormente.

Durante o monitoramento de um campo, vários sensores podem ser integrados ao VANT, como dispositivos de monitoramento de produção, Sistema de Informação Geográfica, do inglês *Geographic Information System* (GIS), Sistema de Posicionamento Global, do inglês *Global Positioning System* (GPS), entre outros. Como não há contato físico entre a plantação e esses dispositivos, é possível adquirir e interpretar medidas sem causar danos à vegetação (NILSSON, 1995; KAIVOSOJA et al., 2013; WIJITDECHAKUL et al., 2016).

O sensoriamento remoto, utilizando GPS integrado, gera um conjunto de dados com localizações geográficas específicas. Dessa forma, é necessário criar métodos para lidar com tarefas encontradas na PA que considerem essa especificidade. Uma provável tarefa é subdividir o campo em partes homogêneas, tanto visualmente quanto nas condições do solo, utilizando a localização geográfica. Essa divisão é conhecida como delineamento de zonas de manejo e tem sido utilizada há muito tempo, porém geralmente era realizada utilizando o conhecimento especializado do campo em questão. Após avanços recentes na tecnologia, esta subdivisão começou também a ser realizada baseando-se em dados de sensores (RUSS; KRUSE; SCHNEIDER, 2010).

Esse trabalho propõe uma técnica para subdividir um campo em zonas de manejo, processando imagens aéreas capturadas por VANTs através do Índice de Vegetação por Diferença Normalizada, do inglês *Normalized Difference Vegetation Index* (NDVI), permitindo ao agricultor localizar determinada zona e identificar o tratamento necessário. Além disso, esta técnica visa realizar tal tarefa num curto espaço de tempo, permitindo análises em tempo real em computadores com baixo poder de processamento e até mesmo em dispositivos embarcados, ambos apresentados neste trabalho. Para realizar essa separação de forma rápida, são realizadas diversas otimizações no algoritmo para NDVI e no algoritmo de clusterização não supervisionado *K-means*.

Como caso de estudo, foram utilizadas imagens de plantação de cana-de-açúcar capturadas por um VANT. Ao final, são apresentadas as imagens classificadas e os dados da avaliação de desempenho da solução proposta, tanto em um computador convencional, quanto em um sistema embarcado. Além disso, para determinar a localização de cada zona de manejo, também foi desenvolvido um sistema de captura de coordenadas geográficas a partir da imagem segmentada do campo.

1.2 Objetivos

1.2.1 Objetivo Geral

Este projeto tem como objetivo principal desenvolver uma solução automática e de rápido processamento para monitorar vegetações por meio de imagens, tanto aéreas, capturadas por VANTs, quanto em solo, capturadas por um sistema portátil, utilizando sistemas com baixo poder de processamento.

1.2.2 Objetivos Específicos

Para alcançar o objetivo geral, esse trabalho conta com os seguintes objetivos específicos:

1. Otimizar o cálculo do NDVI;
2. Otimizar a execução do *K-means*;
3. Separar áreas de vegetação em zonas de manejo;
4. Definir as coordenadas geográficas de áreas de interesse na imagem da cultura analisada;
5. Desenvolver um sistema embarcado que capture imagens e processe-as em tempo real utilizando o NDVI.

1.3 Estrutura da Dissertação

Os capítulos restantes estão estruturados da seguinte forma: o Capítulo 2 apresenta os conceitos necessários para o entendimento deste trabalho. O Capítulo 3 apresenta alguns trabalhos relacionados a esta pesquisa. Já o Capítulo 4 apresenta as tecnologias e os métodos utilizados no desenvolvimento deste estudo. Os resultados, comparações, aplicações e discussões são apresentados no Capítulo 5, seguido pelas considerações finais e bibliografia.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta os conceitos de agricultura de precisão; processo de fotossíntese juntamente com o índice de vegetação NDVI; pré-processamento de imagens; algoritmo *K-means* e processo de transformação de coordenadas de pixel em coordenadas geográficas. A partir desses conceitos, é possível entender toda a explicação descrita no restante deste trabalho.

2.1 Agricultura de precisão e zonas de manejo

O sensoriamento remoto, junto com outras técnicas geoespaciais, têm sido aplicados na agricultura há algumas décadas. Este sensoriamento visa detectar, através de variações nas respostas espectrais e refletâncias, sintomas de infecções antes de serem visíveis aos olhos humanos e diferenças no crescimento da plantação e na condição do solo (GAGO et al., 2015; SANKARAN et al., 2015). As etapas básicas da prática de Agricultura de Precisão (PA), são: coleta de dados, mapeamento de variabilidade de campo, tomada de decisão e prática de gerenciamento, podendo utilizar o sensoriamento remoto nas três primeiras etapas (STAFFORD, 2000).

As plataformas de sensoriamento remoto tradicionais incluem: aviões, helicópteros, satélites e plataformas de sensoriamento em solo equipadas com diversos sensores. Esses sensores são capazes de diagnosticar diversas informações, como: estresse hídrico, doença, biomassa, índice de massa foliar, do inglês *Leaf Area Index* (LAI), entre outros (JIN et al., 2013; WANG et al., 2002). A aplicação dessas plataformas tradicionais na PA é limitada pelo

alto custo, consumo de tempo, cobertura de nuvens em imagens aéreas (KAIVOSOJA et al., 2013; MORIYA et al., 2017) além da possibilidade de erro humano e de danos à vegetação nas plataformas em solo. Enquanto isso, os VANTs e os sistemas portáteis baseados em imagens podem adquirir imagens com alta resolução espacial de forma gerenciável. Portanto, em determinadas situações, o uso de tais plataformas poderia substituir, com baixo custo, as plataformas tradicionais (JIN et al., 2017; ZHANG; KOVACS, 2012).

De acordo com o tipo de levantamento a ser realizado em uma plantação, vários sensores e câmeras podem ser integrados ao VANT (SANKARAN et al., 2015). Por meio desses sensores é possível avaliar várias características da vegetação, como: crescimento, volume e vigor (ZHANG; KOVACS, 2012), além de detectar problemas, como: falhas de plantio, pragas, insuficiência de nutrientes e problemas climáticos (GÉE et al., 2008) (TELLAECHÉ et al., 2008). O GPS é um dos principais sensores integrados ao VANT, através do qual se localiza e tem seu plano de voo traçado, possibilitando também geolocalizar regiões de interesse em um campo.

Comumente, essas regiões de interesse são definidas a partir das amostras de análise de solo e são conhecidas como zonas de manejo, regiões com padrões semelhantes e atributos que devem resultar em um mesmo potencial no rendimento da safra, na eficiência de insumos e no impacto ambiental (PEDROSO et al., 2010). Por possuírem padrões semelhantes, essas áreas agrupadas podem receber o mesmo tratamento, como aplicação de fertilizantes, irrigação, defensivos agrícolas, entre outros. As informações mais utilizadas na definição de zonas de manejo são os dados de solo do campo, como: mapas de condutividade elétrica aparente do solo, mapas de produtividade, mapas de fertilidade do solo e mapas de matéria orgânica. Para delimitação das zonas podem ser empregadas técnicas de agrupamento de dados através de algoritmos de clusterização não-supervisionados, utilizando a base de dados obtida em solo.

Nos últimos anos, com o crescimento no uso de processamento de imagens e visão computacional na PA, houve um interesse no estudo da divisão de zonas de manejo usando imagens aéreas. Para efetuar essa análise, são comumente utilizados os Índices de Vegetação, do inglês *Vegetation Index* (VI). Neste trabalho as zonas de manejo são separadas utilizando o Índice de Vegetação por Diferença Normalizada (NDVI).

2.2 Fotossíntese e Índice de Vegetação por Diferença Normalizada (NDVI)

Durante o processo de fotossíntese, as plantas absorvem da luz solar, como fonte de energia, principalmente os comprimentos de onda azul e vermelho. Ao mesmo tempo, refletem comprimentos de onda verde, por isso geralmente são percebidas nessa cor, e também refletem muito Infravermelho Próximo, do inglês *Near Infrared* (NIR) (Figura 2.1-A). Plantas saudáveis refletem muito mais NIR do que plantas doentes (Figura 2.1-B), dessa forma, a análise da absorção e reflexão em comprimentos de onda do NIR e do espectro visível, do inglês *Visible Spectrum* (VIS), pode fornecer informações sobre a saúde e a produtividade das plantas (CHANG et al., 2013; RAHMAN; ISLAM; RAHMAN, 2004). Por esse motivo, a detecção da radiação refletida do NIR por satélites possibilita aos cientistas estudarem a vegetação a partir do espaço sideral (NASA, 2016).




Figura 2.1: (A) Processo de absorção de luz visível e reflexão de luz IR durante a fotossíntese. Adaptada de: (NASA, 2016); (B) Refletância espectral de planta saudável, planta doente e solo nos comprimentos de onda visível e NIR. Adaptada de: (CHANG et al., 2013).

Atualmente, é possível encontrar na literatura a utilização de fotografias aéreas medindo a quantidade de NIR refletido por plantas, permitindo identificar se estas estão saudáveis ou em estresse (GAGO et al., 2015; CHANG et al., 2013). Para monitorar essa refletância são utilizadas câmeras multiespectrais ou hiperespectrais ou até mesmo câmeras digitais sem filtro IR. Quando se captura uma imagem com uma câmera sem o filtro IR são capturados o VIS e o NIR juntos. Para separar a captação de NIR e de VIS, um filtro é colocado na frente do sensor de captura de imagens, permitindo passar apenas os espectros azul (ou vermelho)

e NIR e será doravante referido como “filtro passa-azul” (ou “filtro passa-vermelho”). É possível utilizar tanto o filtro passa-azul quanto o vermelho pois, como visto, as plantas absorvem estes dois comprimentos de onda durante a fotossíntese. Quando o filtro passa-azul é colocado na câmera, todo VIS é bloqueado, exceto o azul, sendo possível capturar o VIS e o NIR em canais diferentes. A importância de separar VIS de NIR reside em possibilitar o cálculo do Índice de Vegetação por Diferença Normalizada (NDVI). Ao analisar apenas os canais azul e vermelho, o canal vermelho detecta apenas NIR.

O NDVI tem sido muito utilizado na literatura para estimar a cobertura da vegetação, prever o rendimento das colheitas (HUANG et al., 2014), identificar padrões de cultivo (ZHENG et al., 2015), identificar estresse em plantas (BARTON, 2012), entre outros. Seu cálculo é realizado para cada pixel da imagem, varia de -1 a 1 e indica o vigor de uma vegetação, então quanto maior o valor do índice, maior o vigor da planta (GUERRERO; HINOJOSA-CORONA; KRETZSCHMAR, 2016). Plantas saudáveis absorvem a maior parte do VIS que as atingem, mas refletem a maior parte do NIR. Para separar plantas saudáveis de doentes é preciso medir quanto VIS e quanto NIR estão sendo refletidos. O NDVI permite efetuar essa medição, calculado por meio da Equação 2.1:

$$NDVI = \frac{(NIR - VIS)}{(NIR + VIS)} \quad (2.1)$$

Neste trabalho, o NDVI é calculado utilizando o canal vermelho como NIR e o azul como VIS.

A Figura 2.2 apresenta um exemplo do uso do NDVI para diagnosticar uma planta. Na árvore saudável, à esquerda, metade do NIR é refletido enquanto apenas 8% do VIS é refletido, gerando um NDVI de 0,72. Já a árvore doente, à direita, reflete 40% do NIR, pouco menos que a saudável, mas muito mais VIS é refletido, 30%, gerando um NDVI de 0,14, muito menor que o da planta saudável.

Existem outros índices utilizados na análise de vegetação, porém o NDVI foi escolhido para ser utilizado neste trabalho por ser um dos mais aplicados na literatura (MELO et al., 2017), por sua simplicidade, eficiência e baixo custo de obtenção. Enquanto outros índices necessitam de câmeras especiais multiespectrais ou hiperespectrais de alto custo, é possível calcular o NDVI utilizando uma câmera digital comum. Quando se trabalha com imagens, todas devem passar pelas mesmas técnicas de pré-processamento (JAIN; KASTURI;




Figura 2.2: Exemplo do resultado do NDVI em uma planta saudável à esquerda e uma doente à direita utilizando a equação $NDVI = \frac{(NIR - VIS)}{(NIR + VIS)}$. Adaptada de: (WIKIMEDIA, 2009).

SCHUNCK, 1995). Neste trabalho, as principais técnicas adotadas foram a filtragem de ruídos e a equalização do histograma.

2.3 Pré-processamento de imagens

Essa seção apresenta as etapas de pré-filtragem utilizadas para balancear as imagens de entrada.

2.3.1 Filtragem de ruídos

Em Processamento Digital de Imagens (PDI) a remoção de ruídos é realizada através da aplicação de filtros de suavização de imagem. Dentre os diferentes tipos, um dos mais empregados é o filtro da mediana. Para utilizá-lo é necessário fornecer o tamanho da vizinhança, ou seja, a área de pixels a ser utilizada no processo de filtragem, onde o valor do pixel central é substituído pelo valor da mediana estatística dos pixels da sua vizinhança (Figura 2.3).

A mediana M é o valor central de um conjunto ordenado de valores, ou seja, a metade do conjunto é menor ou igual a M e a outra metade é maior ou igual a M . Dessa forma, na vizinhança da Figura 2.3-A, M é o 5º maior valor do conjunto da Figura 2.3-B. Conse-

A

5	10	10
7	40	10
25	10	10

B

5	7	10	10	10	10	10	25	40
---	---	----	----	----	----	----	----	----

C

5	10	10
7	10	10
25	10	10

Figura 2.3: (A) Vizinhança 3x3; (B) Ordenação do conjunto de valores da vizinhança e determinação da mediana (cor verde) e (C) Substituição do valor do pixel central pela mediana.

quentemente, ao aplicar esse filtro, há um aumento nas exigências computacionais, por ser necessário ordenar o conjunto de pixels da vizinhança (GONZALEZ; WINTZ, 2007).

Este filtro é muito utilizado porque a mediana tem uma melhor resistência à criação de valores divergentes (irreais) de pixels. Dessa forma, para determinados tipos de ruídos, além de uma excelente filtragem, ajuda a preservar detalhes finos de alta frequência na imagem, como bordas e contornos. Além disso, essa filtragem força pontos com diferentes níveis de cinza a ficarem mais parecidos com seus vizinhos. Por exemplo, na Figura 2.3-A com vários valores iguais, o elemento central receberá o valor 10 (Figura 2.3-C) (SOLOMON; BRECKON, 2000).

Existe um tipo particular de ruído definido como “sal e pimenta” por sua aparência com pontos pretos e brancos sobrepostos na imagem. Filtros da mediana são particularmente efetivos na presença desse tipo de ruído. A imagem utilizada nesse processo de filtragem é aquela contendo os valores de NDVI, que se apresenta muito parecida com imagens contendo ruído “sal e pimenta”, e apesar dos valores divergentes de NDVI não serem precisamente ruídos, neste trabalho serão considerados como ruídos por ser almejado como resultado uma imagem com menos discontinuidades.

Após a remoção dos ruídos, a imagem segue para a etapa de equalização do histograma.

2.3.2 Equalização

O histograma de uma imagem com baixo contraste encontra-se muito concentrado em apenas uma região. Para este estudo, uma boa imagem possui pixels de todas as regiões do histograma, tornando mais fácil a visualização da distribuição das intensidades dos pixels. O processo de melhorar a distribuição dos pixels da imagem melhora o seu contraste e é

conhecido como equalização do histograma (Figura 2.4) (OPENCV, 2015). No histograma da Figura 2.4-A é possível visualizar a concentração das intensidades dos pixels numa região mais clara (entre 120 e 200). No histograma da Figura 2.4-B, após a equalização, a intensidade dos pixels são distribuídos no histograma de uma forma mais uniforme.




Figura 2.4: (A) Imagem original com baixo contraste e seu histograma; (B) Imagem após processo de equalização e seu histograma apresentando um aumento do contraste. Fonte: (OPENCV, 2015).

Após a etapa de equalização, a imagem encontra-se preparada para ser segmentada. Neste trabalho, essa segmentação e separação de áreas de interesse é realizada pelo algoritmo de classificação não supervisionada *K-means*.

2.4 Algoritmo *K-means* para Segmentação de Imagem

O algoritmo *K-means* é uma técnica iterativa utilizada para particionar vários objetos em K partições ou *clusters*. Este algoritmo é muito popular na área de segmentação de imagens, principalmente por sua simplicidade, e é responsável por reduzir os 2^8 tons de cinza ou as 2^{24} cores RGB de uma imagem em K cores (LIN et al., 2014) (DALIMI et al., 2015). As etapas do algoritmo são descritas a seguir:

1. Inicialize os K centroides, um para cada *cluster*, aleatoriamente ou baseado em alguma heurística;
2. Calcule a distância euclidiana de cada pixel aos K centroides e atribua o pixel ao *cluster* mais próximo;
3. Atualize o centroide de cada *cluster*, calculando a média de todos os pixels do *cluster*;

4. Repita os passos 2 e 3 até não haver mais mudança nos centroides da iteração atual, quando comparados à iteração anterior, ou até atingir um determinado número de repetições.

Para geolocalizar áreas de interesse em uma imagem, é necessário desenvolver um sistema capaz de transformar coordenadas de pixel em coordenadas geográficas.

2.5 Transformação de coordenadas de pixel em coordenadas geográficas

Para capturar coordenadas geográficas a partir de coordenadas de pixel é necessário utilizar um ortomosaico com coordenadas geográficas associadas, mais conhecido na área de geolocalização por arquivo raster. Um arquivo raster é uma matriz de células, ou pixels, organizada em linhas e colunas, onde cada célula contém um valor representando informações, como, por exemplo, coordenadas geográficas (Figura 2.5). Exemplos desse tipo de arquivo são: fotografias aéreas digitais, imagens de satélites, imagens digitais e mapas digitalizados.




Figura 2.5: Organização de um arquivo raster onde cada célula tem sua posição definida pelos seus valores de linha e coluna. Adaptada de: (ARQGIS, 2016).

As vantagens de armazenar os dados em um arquivo raster são (ARQGIS, 2016):

- Uma estrutura de dados simples - uma matriz de células com valores representando uma coordenada e, às vezes, vinculada a uma tabela de atributos;
- Um formato para análise espacial e estatística avançada;
- A capacidade de representar superfícies contínuas e realizar análises de superfície;

- A capacidade de armazenar pontos, linhas, polígonos e superfícies de maneira uniforme.

Neste trabalho, como entrada, foi utilizado um ortomosaico no formato TIFF (Formato de Arquivo de Imagem com Tag, do inglês Tagged Image File Format), arquivo raster onde cada pixel contém as informações necessárias para capturar suas informações geográficas. Para manipular o arquivo raster, foi utilizada a GDAL, uma biblioteca tradutora de código aberto para formatos de dados geoespaciais raster (GDAL, 2019a). Para relacionar posições rasterizadas (coordenadas de pixel) com coordenadas georreferenciadas é utilizada uma transformação afim (GDAL, 2019b). Esta transformação consiste de seis coeficientes que mapeiam coordenadas de pixel para o espaço georreferenciado.

O fluxograma da Figura 2.6 demonstra o funcionamento do algoritmo de transformação de coordenadas de pixel em latitude e longitude. Inicialmente, a imagem .tif é aberta e, dessa forma, representa uma base de dados GDAL contendo os coeficientes da transformada afim e o sistema de coordenadas geográficas retornado pelo GPS no momento de criação do mosaico, dentre outras informações. Neste trabalho o sistema de coordenadas retornado é o Sistema Geodésico Mundial de 1984, do inglês *World Geodetic System 84* (WGS 84), utilizado pelos GPSs atuais, no qual as coordenadas são definidas em latitude e longitude. Após aplicar a transformada afim, tendo as coordenadas de pixel no espaço georreferenciado e o sistema de coordenadas da base (WGS 84), é possível transformar as coordenadas no espaço georreferenciado em latitude e longitude.




Figura 2.6: Fluxograma do funcionamento da transformação de coordenadas de pixel em latitude e longitude.

Capítulo 3

Trabalhos Relacionados

Na literatura, algoritmos de classificação, como o *K-means*, são muito empregados na segmentação de imagens agrícolas ou classificação de dados de solo para produzir zonas de manejo, sendo a aplicação de dados de nutrientes ou outras medidas de solo a forma mais utilizada e estudada na literatura, como nos trabalhos (RUSS; KRUSE; SCHNEIDER, 2010), (SANTOS; SARAIVA, 2015) e (HE et al., 2011). Porém, nos últimos anos houve um aumento no estudo da separação de zonas de manejo utilizando dados de índices de vegetação, principalmente o NDVI, por meio de imagens multiespectrais, podendo citar os estudos (LIU et al., 2017), (PEDROSO et al., 2010), (LI et al., 2005), (SILVA et al., 2017) e, inclusive, o proposto neste trabalho.

Em (RUSS; KRUSE; SCHNEIDER, 2010) é proposto um algoritmo utilizando o método Clusterização Aglomerativa Hierárquica, do inglês *Hierarchical Agglomerative Clustering* (HAC), uma técnica na qual é gerada uma estrutura em forma de árvore de clusters. Nesse método, pares de clusters são unidos à medida que se sobe na hierarquia, de acordo com a semelhança entre estes. Os autores usam o *K-means* na fase inicial para dividir o campo em pequenos sub-campos, sendo gradativamente agrupados aos pares até formar a quantidade de zonas definida como critério de parada. Como dados de entrada, são utilizadas medidas de condutividade elétrica aparente, índices de vegetação, dados de fertilizante e de produtividade. Como resultado, os autores apontam uma correlação entre seus dados e as medidas de condutividade elétrica, dados mais utilizados para realizar a classificação de zonas.

No estudo (SANTOS; SARAIVA, 2015) é apresentado um modelo de referência, descrevendo todas as atividades, subprocessos, fluxos e decisões necessárias para delimitar zonas

de manejo corretamente. Para demonstrar a aplicabilidade do modelo, o autor apresenta um estudo de caso em uma plantação de trigo. São utilizados dados de nutrientes e de propriedades físicas do solo, além de mapas de produtividade e de altitude. No agrupamento dos dados e formação de zonas de manejo é utilizado o algoritmo *Fuzzy C-means*. O autor também comparou o resultado obtido pelo *C-means* com o *K-means* e não encontrou diferenças significativas.

Já na abordagem de separação de zonas de manejo apresentada em (LIU et al., 2017) os autores utilizam o eCognition, um software para análise de imagens que utiliza um método de segmentação orientado a objetos. Como entrada, são utilizados dados de nutrientes de solo de um campo de soja e dados de NDVI calculados a partir de imagens multiespectrais capturadas pelo satélite SPOT6/7. Como resultado, os autores concluíram que a delimitação das zonas através de dados de solo é similar à utilizando dados de NDVI e que o método proposto tem alta precisão, baixo custo, e economiza recursos humanos e materiais.

No trabalho (PEDROSO et al., 2010) o autor propõe um algoritmo para segmentação de zonas de manejo baseado no algoritmo de *Region-merging*. Inicialmente, a imagem é dividida em várias áreas. Em seguida, áreas vizinhas são agrupadas, baseadas na semelhança dos seus dados, até alcançar a quantidade de zonas definidas como critério de parada. A vantagem do algoritmo é permitir sua aplicabilidade em dados irregulares, como os de produtividade e de NDVI. Para estudo de caso, foram utilizadas imagens aéreas NDVI de plantações de uva, capturadas pelo sensor multiespectral Leica ADS40, e os autores obtiveram resultados equivalentes ou superiores ao método de classificação adotado no estado da arte.

(LI et al., 2005) desenvolve um novo método de segmentação baseado no *K-means* definido como Agrupamento Espacial Contíguo *K-means*, do inglês *Spatial Contiguous K-Means* (SC-KM). Segundo o autor, este algoritmo, diferentemente de outros algoritmos de classificação não supervisionada, leva em consideração a interação espacial entre as células (pixels), causando uma melhor continuidade espacial. Foram utilizados dados de NDVI calculados a partir de imagens multiespectrais capturadas por um avião tripulado, utilizando o Espectrômetro de Imagens Modulares Operacionais, do inglês *Operational Modular Imaging Spectrometer* (OMIS). Os resultados mostram não existir diferença significativa na segmentação de zonas pelo método SC-KM apresentado e pelo *K-means* tradicional, porém o

SC-KM removeu muitas células ou manchas isoladas, melhorando a continuidade do mapa e proporcionando zonas de manejo mais eficazes.

Embora as soluções apresentadas utilizando dados de NDVI na segmentação de zonas de manejo provejam diversos benefícios, um dos principais problemas encontrados nessas abordagens é a utilização de imagens de satélites ou de sensores multiespectrais específicos, porque essa solução torna-se muito custosa, principalmente quando se fala em agricultura de pequena ou média escala. Porém, existe uma falta de estudos utilizando imagens multiespectrais capturadas por câmeras digitais IR de baixo custo como possível solução. Apenas o trabalho (SILVA et al., 2017) foi encontrado com este propósito, onde são utilizadas imagens aéreas NDVI registradas por uma câmera digital RGB modificada para capturar imagens Infravermelho Próximo-Verde-Azul, do inglês *NIR-Green-Blue* (NGB).

Na literatura, vários trabalhos apresentam soluções para acelerar a segmentação de imagens utilizando o *K-means*, porém os estudos (CHEN; CHEN; CHIEN, 2008; SILVA et al., 2017) notabilizaram-se pela simplicidade da abordagem utilizada. Em ambos, a definição dos centroides ótimos é realizada utilizando dados do histograma da imagem, em substituição aos pixels normalmente utilizados, reduzindo a complexidade computacional desse processo. Em (SILVA et al., 2017) os autores utilizam dados de NDVI para delimitação das zonas de manejo e utilizam suavização e equalização como etapas de pré-processamento da imagem NDVI. Após pré-processar a imagem, o algoritmo *K-means* é aplicado no histograma e, ao final, cada pixel é atualizado no centroide mais próximo, delimitando as zonas de manejo.

Esse trabalho visa suprir a escassez de estudos utilizando câmeras multiespectrais de baixo custo e o processamento de imagens NDVI em computadores com baixo poder de processamento, incluindo sistemas embarcados, além de permitir demarcar pontos na imagem segmentada e obter suas coordenadas geográficas. Tal informação fornece embasamento para tomada de decisão quanto ao manejo adequado das zonas delimitadas, permitindo sua localização de forma mais acertada.

Neste trabalho, a metodologia de separação em zonas de manejo segue um processo parecido com o proposto em (SILVA et al., 2017), porém foram realizadas diversas otimizações com o propósito de processar imagens de vegetações em computadores de uso pessoal (sem alto poder de processamento) e também capturar e processar imagens em tempo real utili-

zando sistemas embarcados. Além disso, também é possível demarcar áreas de interesse e obter suas localizações geográficas. A Tabela 3.1 apresenta um resumo das características e contribuições dos trabalhos apresentados, juntamente com as do trabalho aqui proposto.

Tabela 3.1: Comparação das principais contribuições dos trabalhos relacionados juntamente com o proposto.

Trabalho	Segmentação		Entrada		Câmera		Sistema Embarcado	Geolocalização das zonas
	K-means	outros	medidas de solo	NDVI	multiespectral	digital IR		
(RUSS; KRUSE; SCHNEIDER, 2010)	✓	✓	✓					
(SANTOS; SARAIVA, 2015)		✓	✓					
(HE et al., 2011)		✓	✓					
(LIU et al., 2017)		✓	✓	✓	✓			
(PEDROSO et al., 2010)		✓		✓	✓			
(LI et al., 2005)	✓			✓	✓			
(SILVA et al., 2017)	✓			✓		✓		
Trabalho proposto	✓			✓		✓	✓	✓

Capítulo 4

Metodologia

Este capítulo detalha todas as etapas seguidas no desenvolvimento do sistema, desde a captura e preparação das imagens, passando pela otimização do NDVI, do *K-means* e a análise de vegetações nas imagens capturadas e, por fim, o processo de captura das localizações geográficas de pontos demarcados na imagem.

Este capítulo detalha todas as etapas seguidas no desenvolvimento de dois principais sistemas, desde a captura e preparação das imagens, passando pela otimização do NDVI, do *K-means* e a análise de vegetações nas imagens capturadas. O primeiro, denominado *sistema aéreo*, é responsável por calcular o NDVI em um mosaico da vegetação, segmentá-lo em zonas de manejo, identificando-as por meio de cores e, por fim, capturar localizações geográficas de pontos demarcados no mapa de zonas de manejo. Todo este processamento é executado em um computador convencional, após a captura das imagens por um VANT. O segundo, denominado *sistema portátil*, trata-se de um dispositivo portátil, desenvolvido neste estudo, que captura imagens em solo e realiza a análise da vegetação, colorindo-as conforme os valores de NDVI.

4.1 Captura e preparação das imagens aéreas

As imagens do campo analisado são capturadas pela câmera digital Pi NoIR, módulo criado para ser utilizado pela Raspberry Pi, possui 8 megapixels de resolução e um sensor de imagem CMOS. Esta câmera não possui filtro infravermelho e fornece os espectros NIR-G-B (Infravermelho Próximo, verde e azul). Para possibilitar o cálculo do NDVI, também é uti-

lizado na câmera o filtro Roscolux *Storaro Blue*, permitindo-a capturar predominantemente os espectros azul e NIR, como é possível observar na Figura 4.1. Em (MASSANO, 2018) esse filtro foi utilizado no desafio europeu *Astro Pi*, permitindo estudantes realizarem experimentos utilizando computadores Raspberry Pi dentro da Estação Espacial Internacional, viabilizando observar a saúde e o crescimento de vegetações terrestres a partir do espaço sideral. Na Figura 4.2 são apresentados a Pi NoIR e o filtro utilizados neste estudo.




Figura 4.1: (A) Gráfico do filtro *Storaro Blue*, cuja função é garantir uma maior captura pela câmera dos comprimentos de onda azul (entre 440 e 480 nm) e infravermelho próximo (entre 740 e 950 nm). Adaptada de: (MASSANO, 2018).




Figura 4.2: Filtro *Storaro Blue* junto à câmera Pi NoIR.

A câmera encontra-se acoplada à Raspberry Pi Zero e todo o sistema embarcado em um VANT do tipo asa fixa, construído em (MELO et al., 2017). Após o voo, as imagens capturadas são descarregadas no sistema, porém o processo seria muito dispendioso se o

algoritmo fosse aplicado em cada imagem separadamente, pela quantidade de imagens e por estas terem muita sobreposição.

A Figura 4.3 apresenta algumas das imagens capturadas pelo VANT. Após a captura, é realizada a composição dessas imagens individuais, gerando o ortomosaico da Figura 4.4-A, imagem única constituída por todo o campo a ser analisado. Para realizar este processo é utilizado o software OpenDroneMap. Como é possível visualizar na Figura 4.4-A, o mosaico contém muitas áreas fora do campo monitorado, então uma ferramenta de recorte foi utilizada para selecionar, manualmente, apenas a região de interesse, produzindo como saída a imagem da Figura 4.4-B. Esta imagem será a entrada do algoritmo de delimitação de zonas de manejo.



Figura 4.3: Algumas imagens capturadas pelo VANT durante o voo.




Figura 4.4: (A) Mosaico criado no software OpenDroneMap; (B) Mosaico recortado mantendo apenas a região de interesse.

O cálculo do NDVI e a clusterização demandam muito processamento, elevando o tempo de execução à medida que o tamanho da imagem aumenta. Para resolver este problema, são adotadas técnicas para otimizar tanto o cálculo do NDVI quanto a segmentação da imagem pelo *K-means* e estas serão abordadas nas Seções seguintes.

4.2 Otimização do cálculo do NDVI

Como o cálculo do NDVI é realizado para cada pixel da imagem, ao utilizar uma imagem muito grande, por exemplo, acima de 200 milhões de pixels, foram constatados dois principais problemas lentidão e, após grande período de espera, estouro de memória. Durante o levantamento bibliográfico não foram identificadas soluções específicas para otimizar o cálculo do NDVI. Dessa forma, foram realizados variados testes comparativos de desempenho até serem obtidas as soluções adotadas a seguir:

1. **Array Numpy:** estrutura de dados escolhida para a aplicação por sua eficiência de uso de memória e por oferecer operações numéricas rápidas (NUMPY, 2018). Em um array Numpy, cada elemento ocupa a mesma quantidade de bytes e é armazenado de forma adjacente num endereço particular no sistema de memória. O fato dos itens serem armazenados de maneira contínua na memória permite a utilização de instruções vetorizadas da Unidade de Processamento Central, do inglês *Central Processing Unit* (CPU), implementadas na linguagem C, aumentando a velocidade e a eficiência no acesso aos dados (WALT; COLBERT; VAROQUAUX, 2011). A utilização dessa estrutura de dados é crucial para as soluções seguintes.
2. **Economia de cópia de imagens:** a cada execução de uma etapa do algoritmo, uma nova imagem de saída é gerada. Por exemplo, após o processamento da imagem de entrada RGB, é gerada como saída uma imagem NDVI de mesmo tamanho, então, no lugar de criar uma nova estrutura de dados para guardar a imagem de saída, a mesma variável da imagem de entrada é utilizada, sobrescrevendo-a neste momento, permitindo economizar o uso de memória.
3. **Economia de bits:** Por padrão, ao criar um array Numpy, o seu tipo numérico é definido automaticamente, porém nem sempre a sua quantidade de bits é realmente necessária. Neste trabalho, ao criar um array Numpy, o seu tipo é sempre definido manualmente, utilizando apenas a quantidade de bits necessária. Por exemplo, ao definir uma variável inteira, no lugar de usar um *int* com 32 bits, pode ser utilizado um *int* com 16 bits, ou com 8 bits sem sinal etc. Essa otimização também permite principalmente economia no uso de memória.

4. **Utilização de slicing:** a utilização de laços *for* é um ponto crítico no tempo de processamento de uma aplicação. Então, sempre quando possível, é utilizada a sintaxe *slicing* na substituição de laços de repetição sobre matrizes. Por exemplo, para acessar apenas os valores da cor verde em uma imagem RGB, no lugar de utilizar um laço *for* duplo para percorrer toda a matriz, basicamente é possível retornar todos esses valores com um *slicing* do tipo *image[:, :, 1]*.

4.2.1 Otimização do *K-means*

A *scikit-learn* é uma biblioteca com diversos algoritmos para mineração e análise de dados, dentre eles o *K-means*. Mesmo otimizado, este algoritmo utiliza a abordagem tradicional, na qual a determinação dos centroides é realizada sobre a imagem de entrada. Então quanto maior a imagem, maior o tempo para segmentá-la. Visando agilizar esse processo, foi realizado um levantamento bibliográfico de estudos que buscam acelerar esta segmentação aplicando o *K-means*. Dentre esses estudos, (SILVA et al., 2017) destacou-se por sua simplicidade na adoção do *K-means* no histograma, em substituição aos pixels da imagem geralmente utilizados. As etapas seguintes apresentam o funcionamento do *K-means* modificado:

1. O histograma da imagem equalizada é obtido, onde os valores no eixo horizontal e vertical representam, respectivamente, as intensidades dos pixels da imagem (de 0 a 255) e suas frequências (quantidades).
2. Os centroides são iniciados cobrindo todo o eixo horizontal. Dessa forma, se o usuário quiser delimitar a quantidade de zonas de manejo em, por exemplo, 5 (cinco), então os centroides iniciais serão 0, 63, 127, 191, 255.
3. Os centroides são atualizados pela média ponderada dos pontos dentro de cada *cluster*, com os pesos sendo as frequências dos pixels. Por exemplo, se em um determinado *cluster* existem 10 intensidades, então a Equação 4.1 seria a utilizada.

$$mediaPonderada = \frac{\sum_{k=1}^{10} intensidade_k * frequencia_k}{\sum_{k=1}^{10} frequencia} \quad (4.1)$$

O método foi implementado e testado no mosaico, sendo obtidos resultados visuais similares aos alcançados pela abordagem tradicional. Contudo esse método só seria viável se o tempo de execução fosse menor que o implementado na biblioteca supracitada. A definição dos centroides de um *cluster* no histograma é muito mais rápida do que utilizando a imagem, porém para atualizar cada pixel no seu *cluster* específico, é necessário utilizar estruturas de repetição, pois é necessário comparar cada pixel da imagem com os K centroides definidos, escolher o mais próximo e atualizar o valor do pixel com o valor do centroide escolhido. Dessa forma, foram utilizados dois laços *for*: um duplo, pra percorrer a matriz da imagem; e um simples, para comparar a distância do ponto (pixel) ao array de centroides.

Esse processo de atualização de cada pixel em um *cluster* específico é muito custoso computacionalmente, principalmente quando se tenta utilizar apenas Python. Dessa forma, foi utilizado o Cython, um compilador estático otimizado que permite escrever extensões de linguagem C para Python. Então, os únicos laços *for* necessários em toda a aplicação foram escritos nessa linguagem, possibilitando ao compilador gerar um código em C eficiente a partir do código em Cython, agilizando o processo. Utilizando apenas Python, esse processo durava 36,61 segundos, diminuindo para 3,5 segundos com o Cython. Após estas otimizações, houve uma melhora de 70% no tempo de processamento do *K-means* quando comparado ao tradicional, passando de 11,8 segundos para 3,5 segundos. Vale destacar que para efetuar essa comparação de forma mais justa foi utilizado o *K-means* tradicional otimizado da biblioteca OpenCV. Após as otimizações realizadas, verificou-se a possibilidade de embarcar o algoritmo em um sistema portátil, para capturar e processar imagens locais em tempo real.

4.2.2 Desenvolvimento do sistema portátil, captura e processamento de imagens em solo

Como prova de conceito, um sistema embarcado portátil foi desenvolvido. O principal componente utilizado é a Raspberry Pi 3 modelo B+, um computador de placa única, desenvolvido pela *Raspberry Pi Foundation*, com 1 GB de memória RAM, CPU de quatro núcleos com 1.4 GHz de frequência e GPU integrada de quatro núcleos com um clock de 300 MHz. Mesmo pequena, 85 x 56 x 17 mm, a placa funciona como um minicomputador e possui

considerável poder de processamento. Portanto, é possível usar o sistema completo desenvolvido anteriormente sem modificações significativas.

A câmera digital (sem filtro infravermelho) Pi NoIR é acoplada à placa, juntamente ao filtro passa-azul, possibilitando a captura dos espectros azul e NIR utilizados no cálculo do NDVI. Adicionalmente, foi utilizada uma tela de cristal líquido *touch screen* para substituir o monitor, o teclado e o mouse, Figura 4.5-A. Para uma melhor experiência do usuário, foi desenvolvida uma interface gráfica simples para facilitar a operação do sistema (Figura 4.6), utilizando a biblioteca Tkinter, pacote padrão do Python.




Figura 4.5: (A) Sistema portátil internamente apresentando todos os seus componentes; (B) Folha de papel usada para efetuar o balanço de branco na câmera.




Figura 4.6: Interface gráfica do sistema portátil.

No processo de captura de imagens algumas modificações foram realizadas. Assim como outras câmeras de uso comum, a Pi NoIR recebe uma contribuição significativa da região azul do espectro (COBURN et al., 2018), sendo necessário equilibrar os níveis dos canais

de cores (vermelho, verde e azul). Em câmeras de uso comum, existe uma configuração utilizada para executar esse balanço de cores: tal ajuste é realizado apontando o sensor de imagem para uma folha de papel branco ou cinza, tornando os três canais de cores uniforme, e é conhecido como balanço de branco. Realizar este procedimento utilizando uma folha de papel azul, no lugar de branca, permite obter uma melhor separação das curvas dos espectros azul e vermelho (VIS e NIR), produzindo imagens NDVI mais fáceis de interpretar (LAB, 2017).

Diferentemente de uma câmera convencional, todo o processo de captura de imagens realizado pela Pi NoIR deve ser codificado manualmente, inclusive o balanço de branco. Originalmente, a câmera efetua o balanço de branco automaticamente a cada captura de imagem (PICAMERA, 2019). É necessário consultar a documentação da câmera para compreender como modificar estes parâmetros configurados automaticamente. Os principais parâmetros trabalhados nessa etapa são:

- *awb_mode*: define o tipo de balanço de branco efetuado pela câmera, sendo “*auto*” o valor padrão. Esse parâmetro deve ser desligado para possibilitar o ajuste manual;
- *awb_gains*: são os ganhos (quantidade) de azul e vermelho que representam o balanço das cores na câmera.

As etapas do algoritmo executado para realizar o balanço de branco estão descritas a seguir:

1. Inicialize a câmera, apontando o sensor para a uma folha de papel azul de tonalidade média, de modo que preencha todo o quadro da imagem;
2. Aguarde a câmera configurar os valores automáticos de balanço de branco;
3. Salvar em uma variável local os valores de balanço de branco da variável *awb_gains*;
4. Desligar o ajuste automático, trocando *awb_mode* do padrão “*auto*” (automático) para o “*off*” (desligado);
5. Atribuir à *awb_gains* os valores da variável local do item 3.

A Seção 4.3 apresentará todas as etapas do desenvolvimento da aplicação utilizando as melhorias realizadas no NDVI e no *K-means*. E as imagens de entrada do sistema serão ou o mosaico do campo, quando utilizado o sistema aéreo, ou a imagem capturada pelo sistema portátil.

4.3 Sistemas de segmentação de zonas de manejo e de análise de imagens em solo.

Na classificação da imagem de saída, em ambos os sistemas, é utilizado o mapa de cores da Figura 4.7. Seus limites são as cores vermelha (faixa de NDVI mais baixa) e verde escuro (faixa de NDVI mais alta) e significa áreas de vegetação de baixo até alto vigor.



Figura 4.7: Mapa de cores utilizado no sistema. Fonte: (MATPLOTLIB, 2018)

As Figuras 4.8 e 4.9 apresentam, respectivamente, os fluxogramas do funcionamento dos sistemas aéreo e portátil desenvolvidos nesse estudo.




Figura 4.8: Fluxograma do funcionamento do algoritmo de delimitação e geolocalização de zonas de manejo no sistema aéreo a partir do NDVI.




Figura 4.9: Fluxograma do funcionamento do sistema portátil.

A primeira etapa é fornecer ao software a imagem da área a ser analisada. No sistema aéreo, é fornecido o mosaico do campo (Figura 4.10-A) e, no sistema portátil, a imagem fornecida é capturada no mesmo instante. Então calcula-se o NDVI para cada pixel, criando uma matriz de mesma dimensão da imagem original. Após esta etapa, a imagem, antes RGB com três canais de cores de 0 a 255, torna-se uma imagem com apenas um canal de cor com valores de -1 a 1. Como não é possível a sua visualização diretamente na forma RGB, aplica-se o mapa de cores da Figura 4.7 sobre essa imagem, obtendo a Figura 4.10 como saída do sistema aéreo.




Figura 4.10: (A) Ortomosaico de entrada do sistema aéreo, para este estudo; (B) Ortomosaico após o cálculo do NDVI e aplicação do mapa de cores.

É possível visualizar na Figura 4.10-B que, apesar de ser possível identificar áreas com alto e baixo vigor, a imagem apresenta muita descontinuidade, tornando difícil a convergência do algoritmo *K-means* na segmentação de zonas. Para amenizar este problema, primeiramente normaliza-se a imagem para tons de cinza, com valores de 0 a 255, e depois aplica-se

o filtro da mediana.

Como a variação de valores do NDVI é muito pequena (-1 a 1), os valores dos pixels são bem próximos e encontram-se distribuídos apenas em um intervalo específico no histograma, tornando difícil observar sua modificação em diferentes áreas. Então, para aumentar o contraste e melhor distribuir este intervalo, a imagem tem seu histograma equalizado.

Após a equalização, a imagem é segmentada pelo *K-means* e, por fim, aplica-se o mapa de cores da Figura 4.7 para delimitar as zonas de manejo. A etapa do K-means é essencial no sistema aéreo por objetivar a segmentação das zonas de manejo. Porém, esta etapa pode ser dispensada no sistema portátil, pois as imagens são capturadas em solo e processadas individualmente, não sendo imprescindível, neste momento, segmentá-las.

Após a separação das zonas de manejo, no sistema aéreo, e a sua visualização pelo mapa de cores, a próxima etapa é possibilitar ao agricultor identificar no campo os problemas das áreas com baixo vigor e decidir o manejo mais adequado. Para facilitar a localização e possível visita às áreas de interesse, um sistema de geolocalização de pontos demarcados no mapa é implementado nesse estudo.

4.3.1 Sistema de captura de coordenadas

Durante o processo de geração do mosaico, quando são fornecidas as localizações geográficas das imagens de entradas, é gerado um ortomosaico de saída no formato .tif. O mosaico utilizado nesta etapa está apresentado na Figura 4.11-A, com 2115 x 3207 (6.782.805 pixels) e representa uma área de aproximadamente 1,3 hectares. Mesmo não sendo muito grande, ao utilizá-lo no processo de captura de coordenadas, a execução torna-se muito custosa, causando travamentos no sistema ao tentar apresentar a imagem completa. Portanto, duas abordagens são adotadas como solução.

Primeiramente, a imagem utilizada para capturar as coordenadas geográficas é o mapa de zonas de manejo, Figura 4.11-B, pois, após o processo de segmentação, há uma redução de 93% no tamanho do arquivo, devido à redução de até 2^{24} cores distintas RGB para apenas cinco cores distintas, mantendo a mesma resolução em pixels. Para uma imagem pequena, esta diferença já é considerável, entretanto para imagens de campos com muito mais hectares, se torna ainda maior.




Figura 4.11: (A) Ortomosaico no formato TIFF usado na captura de coordenadas; (B) Ortomosaico com zonas de manejo demarcadas usado para demarcar pontos de interesse.

A segunda abordagem empregada é desenvolver um sistema que permita mover, aumentar ou diminuir o zoom, sendo apresentado ao usuário apenas um recorte da imagem com as mesmas referências aos pixels da imagem completa. Essa informação é muito importante, pois é necessário capturar as posições rasterizadas (coordenadas do pixel) na imagem original para mapeá-las às coordenadas georreferenciadas do arquivo .tif utilizando a biblioteca GDAL.

Capítulo 5

Resultados e Discussões

Com o intuito de validar o sistema e de apresentar o seu funcionamento, alguns experimentos foram realizados utilizando o sistema aéreo e o portátil e seus resultados estão descritos nas próximas seções.

5.1 Sistema aéreo - Estudo de caso

O campo monitorado encontra-se localizado no município de Areia/PB, em um ambiente controlado pelo Grupo de Grandes Culturas (GGC) do Campus II da Universidade Federal da Paraíba (UFPB). O terreno possui 3 hectares de área de cana-de-açúcar cultivada. Durante o voo foram capturadas aproximadamente 30 imagens úteis, isto é, sobrepostas entre si, possibilitando a realização da sua composição contendo a área monitorada. A partir destas imagens, o mosaico foi gerado e, após recortada a área de interesse, originou-se a Figura 5.1-A, utilizada como entrada do sistema.

Após calculado o NDVI e normalizado para valores de 0 a 255, a imagem passou para a etapa de suavização. Para efetuar-la, um filtro da mediana foi aplicado com diferentes tamanhos de vizinhança para teste, porém a Figura 5.1-B mostra a imagem com um filtro de vizinhança tamanho 55 x 55. Observa-se na Figura 5.1-B que não existe uma separação visual suficientemente nítida entre as áreas com diferentes valores de NDVI. Consequentemente, o algoritmo de segmentação aplicado inicialmente à imagem 5.1-B não obteve êxito na separação das zonas.

Então, foi realizada a etapa de equalização, aumentando o contraste da imagem e obtendo




Figura 5.1: (A) Ortomosaico da plantação de cana-de-açúcar analisada (B) Imagem NDVI com filtro da mediana e vizinhança de 55x55, (C) Imagem (B) equalizada apresentando uma separação bem delimitada dos valores de NDVI através dos diferentes tons de cinza.

a Figura 5.1-C como saída. A diferença entre as imagens antes, Figura 5.1-B, e após a equalização, Figura 5.1-C, é bastante expressiva. Antes, os valores do NDVI se concentravam em uma faixa bem restrita de valores, impossibilitando observar sua distribuição em determinadas áreas, pois a distribuição dos níveis de cinza da imagem é praticamente a mesma. Depois, quando os valores do NDVI encontram-se melhor distribuídos, nota-se uma separação bem demarcada no intervalo de valores mínimo ao máximo, indo do mais escuro ao mais claro.

A Figura 5.2-A apresenta o resultado de referência obtido utilizando a primeira versão do algoritmo, desenvolvida em (MELO et al., 2017). Nesta, todo o processo de delimitação de áreas de manejo, utilizando intervalos de NDVI, foi feito de forma manual, os intervalos de cores foram definidos após cálculos estatísticos e as cores foram indicadas pelo usuário para cada intervalo.




Figura 5.2: (A) Resultado de referência, (B) Imagem segmentada pelo algoritmo *K-means* tradicional e (C) Imagem segmentada pelo algoritmo *K-means* aplicado ao histograma.

Na Figura 5.2-B é apresentada a saída do sistema após aplicar o *Kmeans* tradicional, en-

quanto na 5.2-C foi adotada a sua versão aplicada ao histograma da imagem, demonstrando não haver diferenças visuais significativas na segmentação ao utilizar a segunda abordagem. Ao comparar a saída do sistema atual com a do resultado de referência, verifica-se que o algoritmo de segmentação conseguiu separar as zonas de manejo de acordo com os valores de NDVI, com a vantagem de todo o processo ser automatizado, informando-se apenas a quantidade de zonas a serem divididas. Também houve uma melhora na qualidade da imagem, com reduzida descontinuidade.

A seguir serão apresentados os resultados, com relação ao tempo de processamento, obtidos pelo sistema com diferentes configurações. Além de comparar a versão atual do algoritmo com a primeira versão, descrita em (MELO et al., 2017), e com o trabalho apresentado em (SILVA et al., 2017).

5.1.1 Desempenho

Além da evolução na aparência da imagem resultante, houve uma melhora significativa na velocidade de processamento da imagem. A Tabela 5.1 apresenta os tempos de processamento obtidos para o mosaico, comparando a primeira versão do algoritmo que gera o resultado de referência e a nova versão desenvolvida neste estudo, utilizando tanto o *K-means* tradicional quanto o *K-means* otimizado. Todas as medições dos tempos de processamento foram realizadas pela função *process_time()* do módulo *time* da linguagem Python. Esta função retorna, em segundos, o tempo de CPU, ou seja, quanto esforço da CPU foi gasto durante uma tarefa (PYTHON, 2019). Esta medida é mais assertiva para medir o tempo de processamento porque o tempo real de execução irá depender do processador utilizado, ou seja, dois processos podem durar o mesmo tempo real, porém um deles usar mais recursos computacionais do que o outro.

Tabela 5.1: Comparação do tempo de processamento (em segundos) de uma imagem de 3280 x 2862 pixels (largura x altura) com diferentes configurações do sistema.

Imagem	Tamanho da vizinhança	Primeira versão	<i>K-means</i> tradicional	<i>K-means</i> no histograma
Mosaico (3280 x 2862 pixels)	35 x 35	82.446 s	15.642 s	5.670 s
	55x55	84.248 s	15.765 s	6.102 s
	75 x 75	85.506 s	15.709 s	6.602 s

Observa-se uma melhora significativa no tempo de processamento ao aplicar o algoritmo deste estudo, comparado ao algoritmo de referência, obtendo uma redução de 92,75%. O mais notável, na diminuição desse tempo, foi a utilização das instruções vetorizadas por meio de Numpy arrays. Antes, o algoritmo utilizava muitos laços *for* em Python, o que tornava o processo lento, pois os dados encontravam-se espalhados na memória, tornando o acesso custoso. Porém, o acesso aos itens é muito mais rápido quando se usa instruções vetorizadas.

As otimizações "Economia de cópia de imagens" e "Economia de bits", referidas na Seção 4.2, permitem especialmente economizar memória, possibilitando ao sistema processar grandes imagens. Por exemplo, após essas otimizações foi possível processar ortomosaicos de até 296.288.152 de pixels no computador utilizado nesse estudo. Também houve uma redução de 61,29% no tempo de execução quando utilizado o *K-means* otimizado, comparado ao *K-means* tradicional, embora ambos exibam resultados similares na segmentação.

Paralelamente, foi realizada uma comparação entre os sistemas desenvolvidos em (SILVA et al., 2017) e neste trabalho. A Tabela 5.2 apresenta uma comparação entre os processadores I7-4700MQ, usado em (SILVA et al., 2017), e o I7-6500U, utilizado neste estudo. É possível verificar que o computador utilizado neste trabalho, apesar de ter um processador mais atual com uma frequência de *clock* um pouco maior, possui um desempenho consideravelmente pior (PASSMARK, 2019), visto que possui a metade da quantidade de núcleos físicos e threads.

Tabela 5.2: Comparação da máquina utilizada em (SILVA et al., 2017) com a deste estudo.

	(SILVA et al., 2017)	Trabalho Proposto
Processador	Intel Core i7-4700MQ	Intel Core i7-6500U
Velocidade de Clock	2.4 GHz	2.5 GHz
Turbo Max	3.4 GHz	3.1 GHz
Número de núcleos	4	2
Número de threads	8	4
Memória	16 GB	8GB
Desempenho(PASSMARK, 2019)	7684	4430

Os autores relatam que o seu algoritmo leva 12 segundos para processar uma imagem de 4387x2021 (8.866.127 pixels). Neste trabalho, o tempo de execução foi de aproximadamente 6 segundos para processar um mosaico com 3280x2862 (9.387.360 pixels), uma redução de

pelo menos 50%, mesmo desconsiderando a diferença entre os computadores. O código fonte do sistema desenvolvido neste trabalho não faz uso de nenhuma característica inerente a uma CPU, permitindo presumir uma comparação justa entre os sistemas.

Após a geração do mapa de zonas de manejo, a próxima etapa é realizar a localização geográfica das áreas de interesse, e os resultados obtidos para o sistema de localização são apresentados a seguir.

5.1.2 Sistema de captura de coordenadas

A Figura 5.3 apresenta algumas das diversas configurações possíveis na apresentação da imagem pelo sistema de demarcação de pontos nas áreas de interesse. O sistema permite aumentar e diminuir o *zoom*, mover e apresentar toda ou partes da imagem, mantendo sua relação com a imagem original.




Figura 5.3: Diferentes configurações de zoom realizadas na imagem de entrada (A), (B) e (C). Nas imagens o tamanho da tela é o mesmo, mudando apenas o zoom e a movimentação da imagem.

Para verificar as saídas obtidas pelo sistema desenvolvido neste trabalho, foi realizada uma comparação com as saídas obtidas pelo software QGIS, sistema de informação geográfica muito utilizado no meio acadêmico para realizar todo tipo de manipulação em bases de dados geoespaciais. A Figura 5.4-A apresenta a tela do sistema desenvolvido, demarcando quatro pontos com suas numerações correspondentes, indicando a ordem de demarcação. Após o processamento, as coordenadas dos pixels demarcados são transformadas em latitude e longitude. O mesmo processo foi realizado no software QGIS, sendo demarcados os mesmos quatro pontos, como demonstrado na Figura 5.4-B.




Figura 5.4: (A) Demarcação dos pontos 1,2,3 e 4 no sistema desenvolvido; (B) Demarcação dos pontos 1,2,3 e 4 no software QGIS.

A Tabela 5.3 resume os resultados para os quatro pontos demarcados. Percebe-se resultados parecidos em ambos os sistemas, havendo pequenas diferenças entre as coordenadas encontradas. Porém, são diferenças aceitáveis em consequência de não ser possível saber o pixel exato sendo demarcado no software QGIS, usando apenas uma aproximação manual do local demarcado.

Tabela 5.3: Saídas obtidas para cada ponto demarcado no sistema desenvolvido e no software QGIS, mostrando a semelhança nos resultados obtidos em ambos os sistemas.

Ponto	Latitude		Longitude	
	Sistema	QGIS	Sistema	QGIS
1	-34.87286	-34.87287	-7.25704	-7.25704
2	-34.87282	-34.87282	-7.25703	-7.25703
3	-34.87282	-34.87282	-7.25706	-7.25706
4	-34.87284	-34.87284	-7.25704	-7.25705

Após os resultados obtidos, constatou-se a possibilidade de embarcar a solução e ainda assim obter um tempo rápido de processamento. O sistema portátil foi então construído e seus resultados são apresentados a seguir.

5.2 Sistema portátil - Estudo de caso

O algoritmo é iniciado no *boot* do sistema operacional, após o qual é exibida a tela inicial com as opções “Foto” e “Analisar” (Figura 5.5-A), ambas inicialmente desativadas. Em seguida, é realizado automaticamente o balanço de branco. A utilização do sistema é liberada somente após a finalização deste ajuste. Ao clicar em “Foto”, a câmera captura a imagem

(Figura 5.5-B) e, após a captura, ao selecionar o botão “Analisar”, todo o processamento é realizado e o resultado final é apresentado (Figura 5.5-C).




Figura 5.5: (A) Tela apresentando a captura e análise da imagem pelo sistema, (B) Imagem capturada, (C) Resultado obtido com um filtro de vizinhança tamanho 35x35.

O sistema pode ser utilizado em qualquer computador de placa única que opere com o sistema operacional Linux e seja equipada com pelo menos 1 GB de memória RAM. Inicialmente o sistema foi implementado na Tinker, um computador de placa única, desenvolvido pela Asus, com 2 GB de memória RAM, CPU de quatro núcleos com 1.8 GHz de frequência e GPU integrada de quatro núcleos com um clock de 600 MHz. Essa placa é bastante similar à Raspberry, tanto o hardware quanto o software e seu modo de operar, sendo inclusive possível utilizar a Pi Câmera na placa, porém até o presente momento não existe uma forma de executar os ajustes necessário na câmera utilizando esta placa. Como era necessário realizar o balanço de branco na câmera, foi necessário trocar a placa Tinker pela Raspberry, pois, tendo sido a câmera Pi NoIR desenvolvida pela própria Raspberry, existe uma biblioteca própria que permite programá-la modificando os parâmetros necessários. No desenvolvimento do sistema foi utilizada a linguagem de programação Python e especialmente as bibliotecas Numpy, OpenCV e Matplotlib.

Como o objetivo é capturar imagens de vegetação em solo, permitindo uma maior aproximação e consequentemente uma diminuição considerável da imagem, o tamanho da imagem de captura foi configurado para 700 x 705 pixels. A Tabela 5.4 compara os resultados obtidos nas placas Tinker e Raspberry para uma imagem de 700 x 705 pixels (largura x altura) na versão inicial do sistema. Observa-se uma piora no desempenho do sistema quando utilizada a Raspberry PI, comparada à Tinker. Essa piora deve-se ao maior poder de processamento da Tinker, visto que possui o clock de CPU 28% maior, duas vezes mais memória RAM e clock

de GPU. Em termos gerais, após o uso de arrays Numpy e da técnica de *slicing*, no lugar de laços *for*, vê-se uma redução de 99% no tempo de processamento apenas para calcular o NDVI em ambas as placas. Sobre a otimização do *K-means*, o uso da linguagem Cython resultou em uma redução de pelo menos 94%. Todas essas otimizações resultaram em um tempo de processamento total, utilizando *K-means*, de aproximadamente 1,2 segundos na Tinker e 5,19 segundos na Raspberry.

Tabela 5.4: Comparação dos resultados de tempo de processamento (em segundos) obtidos ao processar a Figura 5.5 com 700 x 705 pixels (largura x altura) nas placas Tinker e Raspberry PI.

	Otimização	Tinker	Raspberry
NDVI	Sem	18,52 s	44,88 s
	Com	0,1 s	0,2 s
<i>K-means</i>	Sem	19,93 s	47,89 s
	Com	0,95 s	2,99 s
Demais etapas		0,15 s	2 s
Total		1,2 s	5,19 s

Como relatado anteriormente, o uso do *K-means* no sistema embarcado torna-se opcional por ser dispensável a subdivisão da imagem capturada em solo, assim esta etapa foi retirada quando utilizada a Raspberry. Em compensação, permitiu aumentar a resolução em pixels da imagem para 1088 x 800 pixels, obtendo um tempo de processamento de aproximadamente 0,54 segundos por imagem. Para avaliar o sistema portátil, o seguinte estudo de caso foi realizado.

5.2.1 Cenário

A área analisada encontra-se localizada no município de Santa Rita-PB a uma distância de aproximadamente 30 km de João Pessoa. Foi realizada a análise de dois talhões (unidades mínimas de cultivo) de cana-de-açúcar. Trata-se de duas plantações de cana-de-açúcar pertencentes ao grupo Japungu. Cada talhão é numerado, e neste estudo foram analisados os de número 73 e 64, Figura 5.6.



Figura 5.6: Imagem de satélite mostrando as localizações dos talhões 73 e 64, onde foram capturadas imagens para testar o sistema embarcado.

5.2.2 Captura de imagens




A captura de imagens para este experimento foi realizada no dia 24 de outubro de 2019, no período da manhã. O processo de captura de imagens durou aproximadamente 60 minutos e foram capturadas 33 imagens em solo da cana-de-açúcar dos talhões supracitados, porém apenas 28 imagens foram consideradas úteis, pois cinco estavam repetidas. Originalmente a câmera utilizada efetua um auto ajuste a cada captura fazendo com que cada imagem possua configurações de brilho, contraste e cor diferentes. Contudo, para esse estudo era necessário que as imagens fossem consistentes entre si, para ser possível efetuar uma comparação mais assertiva. Dessa forma, foram realizados dois processos de captura: no primeiro, foi realizado um balanço de branco tradicional, apontando a câmera para uma folha de papel branca; no segundo, foi realizado o balanço de branco apontando para uma folha azul. Em ambos os ajustes, os valores calculados pela câmera são fixados para todas as imagens capturadas, desde a inicialização à finalização do processo. Os resultados obtidos estão descritos na Seção a seguir.

5.2.3 Resultados

Nas Tabelas 5.5 e 5.6 são apresentadas as imagens capturadas, os resultados obtidos e o tempo médio de processamento de cada imagem, obtido após processá-la dez vezes. É possível visualizar que, tanto efetuando o balanço de branco na superfície azul (Tabela 5.5) quanto na branca (Tabela 5.6), os resultados são consistentes para a plantação de cada talhão, resultando em um NDVI mais alto (na faixa do verde) para o talhão 73 e mais baixo

para o talhão 64 (faixa do vermelho ao laranja). Porém, ao utilizar o balanço de branco no azul, houve uma melhor separação nos valores de NDVI em diferentes partes da plantação, sendo este o ajuste utilizado no sistema final. Mesmo os resultados 18 e 19 do talhão 73 apresentando várias áreas nas cores vermelha e laranja, comparando aos resultados do talhão 64, ainda encontram-se na faixa de NDVI mais alta.

Tabela 5.5: Resultados obtidos efetuando o balanço de branco em papel azul.

Item	Imagem	Resultado NDVI	Talhão	Tempo
1			73	0,53s
2			73	0,54s
3			73	0,51s
4			73	0,52s
5			73	0,55s
6			73	0,54s
7			73	0,56s
















8			73	0,50s
9			64	0,52s
10			64	0,53s
11			64	0,55s
12			64	0,53s
13			64	0,53s
14			64	0,57s

Tabela 5.6: Resultados obtidos efetuando o balanço de branco em papel branco.

Item	Imagem	Resultado NDVI	Talhão	Tempo
15			73	0,56s

16			73	0,53s
17			73	0,53s
18			73	0,56s
19			73	0,52s
20			73	0,51s
21			64	0,52s
22			64	0,53s
23			64	0,53s
24			64	0,54s

25			64	0,56s
26			64	0,54s
27			64	0,55s
28			64	0,52s

5.2.4 Discussões

As Figuras 5.7-A e 5.7-C apresentam duas imagens do talhão 73 (itens 3 e 4 da Tabela 5.5) e as 5.7-B e 5.7-D seus respectivos resultados, obtidos após o processamento. Nota-se, pelas imagens dos resultados, maior vigor da plantação, através do predomínio do intervalo de cores verdes. Para uma análise mais precisa, são apresentados nas Figuras 5.8-B e 5.8-D (itens 8 e 2 da Tabela 5.5) os histogramas dos valores NDVI obtidos nas Figura 5.8-A e 5.8-C. No eixo horizontal são apresentados os valores NDVI e, no eixo vertical, as frequências de cada valor NDVI. Podemos observar uma maior prevalência no intervalo de valores acima de 0,2.




Figura 5.7: (A) e (C) Imagens do talhão 73; (B) e (D) Resultados NDVI apresentando um predomínio da cor verde.




Figura 5.8: (A) e (C) Imagens NDVI do talhão 73; (B) e (D) Histograma dos valores NDVI dos recortes das imagens (A) e (C), indicados pelo retângulo preto, apresentando maior prevalência de valores acima de 0,2 demonstrando maior vigor da plantação.

Já as Figuras 5.9-A e 5.9-C são do talhão 64 juntamente com seus resultados 5.9-B e 5.9-D (itens 14 e 11 da Tabela 5.6). Do mesmo modo, as Figuras 5.10-B e 5.10-D apresentam os histogramas de cores de valores NDVI das Figuras 5.10-A e 5.10-C (itens 12 e 14 da Tabela 5.6). Os valores extremos do histograma (abaixo de -0,8 e acima de 0,8) referem-se

ao plano de fundo da imagem onde não há vegetação a ser analisada, pelo que podem ser desconsiderados. No intervalo de interesse para a análise, há uma prevalência no intervalo de valores abaixo de 0,2. Tal prevalência das cores laranja e vermelha confirma o menor vigor da plantação, cujo resultado deve-se à escassez hídrica enfrentada.




Figura 5.9: (A) e (C) Imagens do talhão 64; (B) e (D) Resultados NDVI apresentando um predomínio das cores laranja e vermelha.




Figura 5.10: (A) e (C) Resultados NDVI do talhão 64; (B) e (D) Histograma de cores dos valores NDVI dos recortes das imagens (A) e (C), indicados pelos retângulos pretos, apresentando maior prevalência de valores abaixo de 0,2, faixa de cores vermelho a amarelo, demonstrando menor vigor da plantação.

Mesmo plantados em épocas próximas, o talhão 64 possui um menor desenvolvimento (cana mais baixa), enquanto o 73, além da cana estar mais alta, encontra-se visualmente mais saudável. Os resultados obtidos são esperados, devido ao talhão 73 ser irrigado periodicamente, utilizando a técnica de gotejamento, diferentemente do 64, irrigado apenas pela água da chuva quando esta ocorre.

5.3 Aplicações

Uma das aplicações do software desenvolvido é categorizar visualmente áreas da plantação que necessitam ou não de cuidados, através da segmentação de uma imagem completa da plantação em zonas de manejo. A Figura 5.11-A apresenta o mosaico da área monitorada e a 5.11-B mostra a separação da vegetação em regiões que precisam ou não de cuidados. A imagem foi separada em cinco zonas representadas pelas cores vermelha, laranja, amarela, verde clara e verde escura. As cores vermelha, laranja e amarela representam regiões com baixo vigor, já as cores verdes clara e verde escura representam áreas com alto vigor.




Figura 5.11: (A) Mosaico da área monitorada, (B) Imagem segmentada pelo algoritmo *K-means* separando em áreas de acordo com o vigor da plantação.

Utilizando esse mapeamento de cores, o agricultor é direcionado a dar atenção especial as regiões com cores vermelha, laranja e amarela onde algum tipo de cuidado é necessário, facilitando coletar amostras, identificar o tipo de problema e decidir o manejo mais adequado. Desta forma, viabiliza-se diminuir os custos com adubos, pesticidas e água, além de possibilitar o aumento da produtividade.

Outra aplicação do software desenvolvido é um sistema portátil que permite a pessoas

não treinadas identificar *in loco* se uma planta necessita de cuidados em tempo real. Na Figura 5.12-B toda a parte vegetal é mapeada com cores no intervalo do vermelho e laranja, cuja classificação é de baixo vigor, evidenciando a necessidade de intervenção. Foi confirmada, com o agrônomo responsável, a escassez hídrica sofrida pela planta, visto que esta não é irrigada de acordo com a sua necessidade. A referida Figura evidencia o resultado da classificação da Figura 5.12-A.




Figura 5.12: (A) Imagem da vegetação capturada, (C) Resultado NDVI apresentando baixo vigor da plantação em decorrência da carência de água.

Capítulo 6

Considerações finais

Este estudo apresenta o desenvolvimento de um sistema para monitoramento de vegetação por meio de imagens, tanto aéreas, capturadas por VANTs, quanto em solo, capturadas por um sistema portátil. O principal objetivo foi desenvolver um sistema automático e de rápido processamento, possibilitando embarcar a solução para análise em tempo real. Para atingir esse objetivo, várias técnicas de otimização foram realizadas, tanto no cálculo do NDVI quanto na segmentação da imagem para delimitação das zonas de manejo através do algoritmo *K-means*.

Os resultados mostram a possibilidade de segmentar a imagem de uma plantação em zonas de manejo por meio da utilização do índice de vegetação NDVI em plantações de cana de açúcar de forma rápida e automática. A utilização deste sistema pode ser estendida para outras culturas e outros tipos de análise, não se limitando a análise de alto e baixo vigor (foco deste trabalho). Para um mosaico de imagens com 9.387.360 pixels, foi possível alcançar uma velocidade de processamento de aproximadamente 6 segundos, utilizando um computador portátil convencional. Além disso, para dar suporte ao processo de identificação dos problemas encontrados em zonas com baixo vigor, foi desenvolvido um sistema de demarcação de pontos no mapa, retornando suas coordenadas geográficas. Para verificação, foram comparadas as saídas do sistema desenvolvido neste estudo com as do software QGIS, sendo obtidos resultados equivalentes.

No sistema embarcado desenvolvido neste trabalho, foi possível obter uma velocidade de processamento de aproximadamente 0,54 segundos para analisar uma imagem com 870.400 pixels, permitindo identificar, a partir da comparação dos talhões de cana-de-açúcar anali-

sados no estudo de caso, qual estava sofrendo de escassez hídrica. Este trabalho foi aceito pela comunidade científica através da publicação do artigo "*A Solution for Vegetation Analysis, Separation and Geolocation of Management Zones using Aerial Images by UAVs*" no IX SBESC, *Brazilian Symposium on Computing Systems Engineering*, ademais foi depositado, em Agosto de 2019, no Instituto Nacional da Propriedade Industrial (INPI) o pedido de patente do sistema embarcado aqui desenvolvido.

Bibliografia

ARQGIS. *Raster data*. 2016. Disponível em: <<http://desktop.arcgis.com/en/arcmap/10.3/manage-data/raster-and-images/what-is-raster-data.htm>>.

BARTON, C. V. Advances in remote sensing of plant stress. *Plant and Soil*, Springer, v. 354, n. 1-2, p. 41–44, 2012.

CHANG, J. et al. Using field scouting or remote sensing technique to assess soybean yield limiting factors. In: _____. [S.l.: s.n.], 2013.

CHEN, T.-W.; CHEN, Y.-L.; CHIEN, S.-Y. Fast image segmentation based on k-means clustering with histograms in hsv color space. In: IEEE. *multimedia signal processing, 2008 IEEE 10th Workshop on*. [S.l.], 2008. p. 322–325.

COBURN, C. A. et al. Radiometric and spectral comparison of inexpensive camera systems used for remote sensing. *International Journal of Remote Sensing*, Taylor & Francis, v. 39, n. 15-16, p. 4869–4890, 2018.

DALIMI, H. et al. Segmentation by fusion of histogram-based k-means. *International Journal of Computer Science Issues (IJCSI)*, International Journal of Computer Science Issues (IJCSI), v. 12, n. 4, p. 94, 2015.

DEVADAS, R. et al. Evaluating ten spectral vegetation indices for identifying rust infection in individual wheat leaves. *Precision Agriculture*, Springer, v. 10, n. 6, p. 459–470, 2009.

GAGO, J. et al. Uavs challenge to assess water stress for sustainable agriculture. *Agricultural water management*, Elsevier, v. 153, p. 9–19, 2015.

GDAL. *GDAL*. 2019. Disponível em: <<https://gdal.org/index.html>>.

GDAL. *Raster Data Model*. 2019. Disponível em: <https://gdal.org/user/raster_data_model.html>.

GÉE, C. et al. Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture*, Elsevier, v. 60, n. 1, p. 49–59, 2008.

GONZALEZ, R. C.; WINTZ, P. *Digital Image Processing*. [S.l.]: Pearson, 2007.

GUERRERO, F. J. D. T.; HINOJOSA-CORONA, A.; KRETZSCHMAR, T. G. A comparative study of ndvi values between north-and south-facing slopes in a semiarid mountainous region. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 9, n. 12, p. 5350–5356, 2016.

HE, L. et al. Delineating soil nutrient management zones based on id3 algorithm. In: IEEE. *2011 International Conference on Mechatronic Science, Electric Engineering and Computer (MEC)*. [S.l.], 2011. p. 1155–1159.

HUANG, J. et al. Analysis of ndvi data for crop identification and yield estimation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 7, n. 11, p. 4374–4384, 2014.

JAIN, R.; KASTURI, R.; SCHUNCK, B. *Machine Vision*. McGraw-Hill, 1995. (Computer science series). ISBN 9780071134071. Disponível em: <<https://books.google.com.br/books?id=POSaQgAACAAJ>>.

JIN, N. et al. Hyperspectral identification of cotton verticillium disease severity. *Optik-International Journal for Light and Electron Optics*, Elsevier, v. 124, n. 16, p. 2569–2573, 2013.

JIN, X. et al. Estimates of plant density of wheat crops at emergence from very low altitude uav imagery. *Remote Sensing of Environment*, Elsevier, v. 198, p. 105–114, 2017.

KAIVOSOJA, J. et al. A case study of a precision fertilizer application task generation for wheat based on classified hyperspectral data from uav combined with farm history data. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XV*. [S.l.], 2013. v. 8887, p. 88870H.

LAB, P. *White balance*. 2017. Disponível em: <<https://publiclab.org/notes/cfastie/06-17-2013/white-balance>>.

LI, X. et al. A new algorithm on delineation of management zone. In: IEEE. *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS'05*. [S.l.], 2005. v. 1, p. 4–pp.

LIN, C.-H. et al. Fast k-means algorithm based on a level histogram for image retrieval. *Expert Systems with Applications*, Elsevier, v. 41, n. 7, p. 3276–3283, 2014.

LIU, H. et al. Delineation of site-specific management zone based on spot6/7 remote sensing image in black soil area, northeast china. In: IEEE. *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. [S.l.], 2017. p. 5046–5049.

MASSANO, T. *Rosco Filter Helps Students Observe Earth's Vegetation – From Space!* 2018. Disponível em: <<https://www.rosco.com/spectrum/index.php/2018/03/rosco-filter-helps-students-observe-earths-vegetation-from-space/>>.

MATPLOTLIB. *Choosing Colormaps in Matplotlib*. 2018. Disponível em: <<https://matplotlib.org/tutorials/colors/colormaps.html>>.

MELO, J. C. et al. A system embedded in small unmanned aerial vehicle for vigor analysis of vegetation. 2017.

MORIYA, E. A. S. et al. Mapping mosaic virus in sugarcane based on hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 10, n. 2, p. 740–748, 2017.

NASA. *Reflected Near-Infrared Waves*. 2016. Disponível em: <https://science.nasa.gov/ems/08_nearinfraredwaves>.

NILSSON, H. Remote sensing and image analysis in plant pathology. *Annual Review of Phytopathology*, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 33, n. 1, p. 489–528, 1995.

NUMPY. *NumPy*. 2018. Disponível em: <<http://www.numpy.org/>>.

OPENCV. *Histogram Equalization*. 2015. Disponível em: <https://docs.opencv.org/3.1.0/d5/daf/tutorial_py_histogram_equalization.html>.

PASSMARK. *PassMark - CPU Comparison intel i7-4700MQ vs i7-6500U*. 2019. Disponível em: <<https://www.cpubenchmark.net/compare/Intel-i7-4700MQ-vs-Intel-i7-6500U/1923vs2607>>.

PEDROSO, M. et al. A segmentation algorithm for the delineation of agricultural management zones. *Computers and Electronics in Agriculture*, Elsevier, v. 70, n. 1, p. 199–208, 2010.

PICAMERA. *API - The PiCamera Class*. 2019. Disponível em: <https://picamera.readthedocs.io/en/release-1.13/api_camera.html#picamera.PiCamera.awb_mode>.

PYTHON. *time — Time access and conversions*. 2019. Disponível em: <https://docs.python.org/3/library/time.html#time.process_time>.

RAHMAN, M. R.; ISLAM, A.; RAHMAN, M. A. Ndvi derived sugarcane area identification and crop condition assessment. *Plan Plus*, Citeseer, v. 1, n. 2, p. 1–12, 2004.

RUSS, G.; KRUSE, R.; SCHNEIDER, M. A clustering approach for management zone delineation in precision agriculture. In: *Proceedings of the Int. Conf. on Precision Agriculture*. [S.l.: s.n.], 2010.

SANKARAN, S. et al. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*, Elsevier, v. 70, p. 112–123, 2015.

SANTOS, R. T.; SARAIVA, A. M. A reference process for management zones delineation in precision agriculture. *IEEE Latin America Transactions*, IEEE, v. 13, n. 3, p. 727–738, 2015.

SEELAN, S. K. et al. Remote sensing applications for precision agriculture: A learning community approach. *Remote Sensing of Environment*, Elsevier, v. 88, n. 1-2, p. 157–169, 2003.

SILVA, G. R. et al. Definition of management zones through image processing for precision agriculture. In: IEEE. *Computer Vision (WVC), 2017 Workshop of*. [S.l.], 2017. p. 150–154.

SOLOMON, C.; BRECKON, T. *Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em Matlab*. [S.l.]: Grupo Gen-LTC, 2000.

STAFFORD, J. V. Implementing precision agriculture in the 21st century. *Journal of Agricultural Engineering Research*, Elsevier, v. 76, n. 3, p. 267–275, 2000.

TELLAEACHE, A. et al. A vision-based method for weeds identification through the bayesian decision theory. *Pattern Recognition*, Elsevier, v. 41, n. 2, p. 521–530, 2008.

WALT, S. v. d.; COLBERT, S. C.; VAROQUAUX, G. The numpy array: a structure for efficient numerical computation. *Computing in Science & Engineering*, IEEE, v. 13, n. 2, p. 22–30, 2011.

WANG, D. et al. Determining pecky rice kernels using visible and near-infrared spectroscopy. *International Journal of Food Properties*, Taylor & Francis, v. 5, n. 3, p. 629–639, 2002.

WIJITDECHAKUL, J. et al. Uav-based multispectral image analysis system with semantic computing for agricultural health conditions monitoring and real-time management. In: IEEE. *Electronics Symposium (IES), 2016 International*. [S.l.], 2016. p. 459–464.

WIKIMEDIA. *Wikimedia commons*. 2009. Disponível em: <https://commons.wikimedia.org/wiki/File:Ndvi_example.jpg>.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision agriculture*, Springer, v. 13, n. 6, p. 693–712, 2012.

ZHENG, B. et al. A support vector machine to identify irrigated crop types using time-series landsat ndvi data. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 34, p. 103–112, 2015.