

UNIVERSIDADE FEDERAL DO PARÁ NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

GERSON LIMA SEREJO

ESTIMATIVA DA PRODUÇÃO DE UMA LAVOURA ATRAVÉS DE IMAGENS DIGITAIS CAPTURADAS POR VEÍCULO AÉREO NÃO TRIPULADO (VANT)

Tucuruí/PA 2018

ESTIMATIVA DA PRODUÇÃO DE UMA LAVOURA ATRAVÉS DE IMAGENS DIGITAIS CAPTURADAS POR VEÍCULO AÉREO NÃO TRIPULADO (VANT)

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada do Núcleo de Desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Computação Aplicada.

Orientadora: Profa. Dra. Viviane Almeida dos Santos

Coorientadora: Profa. Dra. Ana Claudia S. Gomes

Tucuruí/PA 2018

FICHA CATALOGRÁFICA

(Expedida pelo sistema on-line da biblioteca

ESTIMATIVA DA PRODUÇÃO DE UMA LAVOURA ATRAVÉS DE IMAGENS DIGITAIS CAPTURADAS POR VEÍCULO AÉREO NÃO TRIPULADO (VANT)

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada do Núcleo de Desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Computação Aplicada.

Orientadora: Profa. Dra. Viviane Almeida dos Santos

Coorientadora: Profa. Dra. Ana Claudia S. Gomes

Aprovada em _____ de _____.

BANCA EXAMINADORA:

Profa. Dra. Viviane Almeida dos Santos – UFPA – Orientadora

Profa. Dra. Ana Claudia S. Gomes – ITV/PA – Coorientadora

Prof. Dr. Otávio Noura Teixeira – UFPA – Membro Interno

Prof. Dr. André Luiz Amarante Mesquita – UFPA – Membro Externo

Prof. Dr. Cristian Berrio Zapata – UFPA – Membro Externo

DEDICATÓRIA

Em especial, a **Jesus Cristo**. Só Ele é a verdade, o caminho e a vida: "Ninguém vai ao Pai se não for por Mim".

Aos meus pais Gilma Lima Serejo e José Maria Pantoja Serejo, que tiveram participação efetiva na minha formação como filho, homem e pai.

À minha esposa Viviane Almeida dos Santos pela dedicação, compreensão e na ajuda deste trabalho e aos meus filhos Vivian dos Santos Serejo e lan dos Santos Serejo e aos meus irmãos Gisele de Lima Serejo da Silva, Jean de Lima Serejo, Weslley Oliveira Serejo e Jefferson Oliveira Serejo.

A minha professora orientadora, Dr^a. Viviane Almeida dos Santos e coorientadora, Dr^a. Ana Claudia S. Gomes pelos ensinamentos, boa vontade, dedicação, paciência e apoio na condução e conclusão deste trabalho.

Aos demais professores Dr. Otávio Noura Teixeira, Dr. André Luiz Amarante Mesquita, Dr. Cristian Berrio-Zapata e Dr. Heleno Fülber do curso de Engenharia de Computação, pela contribuição na analise e correção deste trabalho.

Aos meus colegas de trabalho, pelos incentivos e apoio prestados. Á equipe do ISI - Institutos SENAI de Inovação, em especial aos colegas Dr^a. Ana Claudia S. Gomes, Me. Alexandre Francisco Barral Silva e Dr^a Ana Carolina Q. Siravenha por serem parceiras nesta implementação fornecendo insumos e ajudando a entender o processo estudado.

RESUMO

A utilização de Veículos Aéreos Não Tripulados (VANTs) está se tornando uma ferramenta acessível importante para agronegócios de pequeno e médio porte. A sua aplicação favorece a execução de atividades complexas e trabalhosas, assim como promove novos estudos e desafios para o campo para auxiliar na tomada decisão do produtor rural. O Município de Tucuruí, no Estado do Pará do Brasil, faz parte de uma região que concentra uma grande quantidade de propriedades rurais caracterizadas por serem de agricultura familiar. O objetivo deste trabalho é apresentar um estudo exploratório da aplicação de etapas de Processamento Digital de Imagens (PDI) e Visão Computacional (VC) em imagens capturadas por um VANT para se obter a quantificação de plantas de mandioca e, consequentemente, gerar a estimativa da colheita desta cultura em uma fazenda do município. A contribuição científica deste estudo corresponde aos resultados obtidos da aplicação de 4 índices de vegetação: ExG, ExR, (ExG-ExR) e MaxG. O índice MaxG apresentou o melhor resultado, contando 91% das mudas, no melhor caso, com uma acurácia de 70%. O índice ExR mostrou-se mais apropriado para a contagem das plantas em estágios iniciais de germinação. O índice (ExG-ExR) possibilitou a estimativa com limiarização não supervisionada, o que favorece o desenvolvimento de sistemas de VC para este fim. Já o índice ExG nos surpreendeu apresentando o menor desempenho para o contexto estudado, contando 58% das mudas, no pior caso, com acurácia de 73%. Como contribuições práticas para o agricultor, este estudo possibilitou a conscientização da importância de prever a estimativa da colheita para melhor planejar a negociação da produção, os plantios posteriores e a busca por recursos para aumentar a área mecanizada da cultura. Pesquisas futuras mais aprofundadas precisam ser conduzidas para confirmarem estas conclusões.

Palavras-chave: Veículos Aéreos Não Tripulados, Agricultura Familiar, Imagens Digitais, Quantificação de Plantas, Estimativa da Produção, Índices de Vegetação.

ABSTRACT

The use of Unmanned Aerial Vehicles (UAV) is becoming an important accessible tool for small to medium sized agribusiness. Its application supports the execution of complex and laborious activities, as well as promotes new studies and challenges for the field to assist the farmer's decision making. The County of Tucuruí, in the State of Pará Brazil, is part of a region that concentrates a great amount of rural properties characterized by being of family agriculture. The objective of this work is to present an exploratory study for applying steps of Digital Image Processing (DIP) and Computational Vision (CV) in images captured by a UAV to obtain the quantification of cassava seedlings and, consequently, harvest of this crop in a farm of the county. The scientific contribution of this study corresponds to the results obtained from the application of 4 vegetation indices: ExG, ExR, (ExG-ExR) and MaxG. The MaxG index presented the best result, counting 91% of the seedlings, in the best case, with an accuracy of 70%. The ExR index was more appropriate for counting the seedlings in initial stages of germination. The index (ExG-ExR) allowed the estimation with unsupervised thresholding, which improves the development of CV systems for this purpose. The ExG index surprised us with the lowest performance for the studied context, counting 58% of the seedlings, in the worst case, with accuracy of 73%. As practical contributions to the farmer, this study made it possible to raise awareness of the importance of forecasting the harvest to better plan the negotiation of production, later plantings and the search for resources to increase the mechanized area of the crop. Further indepth research needs to be conducted to confirm these findings.

Keywords: Unmanned Aerial Vehicles, Family Agriculture, Digital Imagery, Plants Quantification, Production Estimation, Vegetation Indices.

LISTA DE ILUSTRAÇÕES

Figura 1 - Sede da Fazenda Bela Vista e a preparação do solo para plantio
com queimadas4
Figura 2 - Banca do agricultor na Feira Municipal de Tucuruí4
Figura 3 - Reservatório de criação de Tilápias5
Figura 4 - Sensor Velodyne HDL-32e, opção LIDAR para VANT. Fonte:
Imagens retiradas do site do fabricante (VELODYNE LIDAR, 2018) 14
Figura 5 - Elementos de um sistema de PDI. Adaptado de (MARQUES FILHO
e VIEIRA NETO, 1999) 15
Figura 6 - Visão geral de um sistema de VC. Adaptado de Marques Filho e
Vieira Neto (1999) 16
Figura 7 – Processo de formação de cores aditivo (RGB) 17
Figura 8 – Espaço de cores em RGB 18
Figura 9 – Imagem bidimensionada é constituída por <i>pixels</i>
Figura 10 – Representação de uma imagem digital bidimensional 19
Figura 11 - Uma imagem digital monocromática: (a) representação gráfica
usual; (b) representação matricial 20
Figura 12 – Imagens área retirada na posição vertical 21
Figura 13 – Fotogrametria recobrimento lateral 30% longitudinal 60%
Figura 14 - Três exemplos de histogramas. Adaptado de Marques Filho e
Vieira Neto (1999)
Figura 15 – Outro exemplo de histograma para a representação de limiares de
tons de cinza
Figura 16 – Exemplo de binarização de uma imagem de planta 33
Figura 17 - Localização da Fazenda Bela Vista
Figura 18 - Imagem de satélite com as coordenadas da área selecionada
3°39'17.0"S 49°46'32.7"W. Acessada em 07 de agosto de 2018. Fonte: Google
Maps
Figura 19 – Mostra a área 63 hectares da fazenda Bela Vista 42
Figura 20 - Área da plantação 1,234ha ou 12.234m ²
Figura 21 - Modelo 3D da plantação com destaque para a área segmentada
(em vermelho)

Figura 22 – O modelo de VANT utilizado neste estudo foi o Phantom 4 da DJI destacando (a) o controle remato, (b) a aeronave e (c) a câmera acoplada ao gimbal. Fonte: imagens retiradas do site do fabricante (DJI PHANTOM 4, Figura 23 – A tela de configuração do aplicativo DroneDeploy, de acordo com as dimensões da área a ser sensoriada. O software mostra: a duração do voo (minutos), a área (hectares), número de imagens, e quantidade de baterias gastas na execução da missão......46 Figura 24 – A tela de upload do aplicativo DroneDeploy......47 Figura 25– Fluxograma das etapas de pré-processamento, aplicação dos índices de vegetação e segmentação das imagens desta pesquisa e sua comparação ao processo manual. 52 Figura 26 – Imagem binarizada do processo manual......53 Figura 27 – Evolução da produtividade (kg/ha) de Mandioca nas Regiões do Figura 28 – Plano de voo da primeira visita no DroneDeploy...... 58 Figura 29 – A imagem (a) representa ortomosaico retirado na primeira visita à fazenda. Comparando com a imagem (b), a área em vermelho representa a ausência de vegetação. Neste local foi realizada a plantação da mandioca, que se encontrava em fase de germinação. 59 Figura 31 – A imagem (a) representa ortomosaico retirado na segunda visita à fazenda. Comparando com a imagem (b), as áreas em vermelho misturadas com áreas em verde representam a presença de vegetação. Neste local foi realizada a plantação que se encontra em fase de brotamento das mudas. ... 60 Figura 32 – Modelo 3D da plantação com destaque para a área segmentada Figura 33 – Culturas de banana e pimenta de cheiro próximas à cultura de mandioca da fazenda......62 Figura 35 – Canais RGB. 63 Figura 36 – Imagem resultante da aplicação do ExG......64 Figura 37 - Histograma resultante do ExG. 64 Figura 38 – Imagem binarizada do ExG+ValorEmp......65

Figura 39 – Imagem após o tratamento realizado na Figura 38	66
Figura 40 – Imagem binarizada do ExG+Otsu.	66
Figura 41 – Imagem do ExG+Otsu após tratamento	67
Figura 42 – Imagem resultante do índice ExR	67
Figura 43 – Histograma do ExR.	68
Figura 44 – Imagem binarizada do ExR+ValorEmp	69
Figura 44 – Imagem após a extração de características do ExR+ValorEmp.	69
Figura 46 – Imagem binarizada do ExR+Otsu	70
Figura 47 – Imagem do ExR+Otsu após o tratamento.	70
Figura 48 – Imagem resultante do índice (ExG-ExR)	71
Figura 49 - Histograma do (ExG-ExR).	71
Figura 50 - Imagem binarizada do (ExG-ExR)+ValorEmp	72
Figura 51 – Imagem da Figura 50 após tratamento	72
Figura 52 – Imagem binarizada do (ExG-ExR)+Otsu	73
Figura 53 – Imagem binarizada do (ExG-ExR)+Otsu após tratamento	73
Figura 54 - Imagem resultante do índice MaxG.	74
Figura 55 - Histograma do MaxG+ValorEmp	74
Figura 56 - Imagem binarizada do MaxG+ValorEmp	75
Figura 57 – Imagem tratada do MaxG +ValorEmp	75
Figura 58 - Imagem binarizada do MaxG+Otsu.	76
Figura 59 – Imagem tratada do MaxG+Otsu.	76

LISTA DE TABELAS

Tabela 1 – Áreas potenciais do emprego de VANT na agricultura de precisão . 6
Tabela 2 - Tipos de sensores acoplados em VANTs para sensoriamento remoto
Tabela 3 - Valor, fator de qualidade e percentual de acurácia dos índices
aplicados
Tabela 4 – Quantidade de mudas, taxa de contagem e imagem binarizada por
índice aplicado77
Tabela 5 – Estimativa da colheita a partir da quantificação das mudas

LISTA DE SIGLAS

- AP Agricultura de Precisão
- VANT- Veículo Aéreo Não Tripulado
- UAVs Unmanned Aerial Vehicle
- CTA Centro Tecnológico Aeroespacial
- NIR Near InfraRed
- FIR Far InfraRed
- RGB Red, Green and Blue
- AUVSI Association for Unmanned Vehicle Systems International
- GMR Green Channel Minus Red Channel
- KI Kindex (KI)
- MaxG Maximum Green Index
- ExG Excess Green Index
- ExR Excess Red Index
- ExG-ExR Excess Green minus Excess Red Vegetation Index
- **GRVI** Green Red Vegetation Index
- NDVI Normalized Difference Vegetation Index
- NDI Normalized Difference Index
- MGRVI Modified Green Red Vegetation Index
- **RGBVI Red Green Blue Vegetation Index**
- CWSI Crop Water Stress Index

- OTSU método de Otsu
- KSR Koller Scientific Reverve (KSR)
- SR Sensoriamento Remoto
- LIDAR Light Detection And Ranging
- SfM Structure from Motion
- PDI Processamento Digital de Imagens
- VC Visão Computacional

SUMÁRIO

1. INTRODUÇÃO	1
1.1 Contexto do problema de pesquisa	3
1.2 Justificativa	5
1.3 Objetivos de Pesquisa	6
1.3.1 Objetivos Específicos	7
1.4 Métodos de pesquisa	7
1.5 Contribuições desta pesquisa	7
1.6 Organização do trabalho	9
2. FUNDAMENTAÇÃO TEÓRICA	. 10
2.1 Uso de VANTs na agricultura de precisão e no sensoriamento remo	to
	. 10
2.2 Conceitos relevantes de Processamento Digital de Imagens (PDI)	. 14
2.3 Fundamentos das imagens digitais	. 17
2.3.1 Modelo RGB	. 17
2.3.2 Imagem digital	. 18
2.3.4 Amostragem e Quantização	. 19
2.3.5 Fotogrametria (aerofotogrametria)	20
	0
2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao	0
2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola 2.4.1 Índices de vegetação 	. 22 . 22
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola 2.4.1 Índices de vegetação	. 22 . 22 . 23
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola. 2.4.1 Índices de vegetação	. 22 . 22 . 23 . 26
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 29
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 29 . 30
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 29 . 30 . 31
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola. 2.4.1 Índices de vegetação	. 22 . 22 . 23 . 26 . 29 . 30 . 31 . 33
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 30 . 31 . 33
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 30 . 31 . 33 a . 34
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 30 . 31 . 33 . 34 . 34
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 30 . 31 . 33 . 34 . 34 . 41 . 41
 2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola	. 22 . 22 . 23 . 26 . 29 . 30 . 31 . 33 . 33 . 34 . 41 . 41 . 44

3.3. Procedimentos metodológicos	47
3.3.1 Domínio do problema	47
3.3.2 Aquisição de imagens	48
3.3.3 Pré-processamento	49
3.3.4 Índices de vegetação escolhidos	50
3.3.5 Segmentação	50
3.3.6 Avaliação da acurácia dos índices	50
3.3.7 Extração de características	54
3.3.8 Reconhecimento e Interpretação	54
3.3.8.1 Contagem das plantas	54
3.3.8.2 Estimativa da produção	55
3.3.8.3 Cálculo da taxa de contagem	55
3.4 Ameaças à validade do estudo	56
4. RESULTADOS	58
4.1 Aquisição das imagens	58
4.2 Pré-processamento das imagens	63
4.3 Processo de Aplicação dos Índices de Vegetação até o Tratamento)
das Imagens	64
das Imagens 4.3.1 ExG (Excess Green Index)	64 64
das Imagens 4.3.1 ExG (Excess Green Index) 4.3.2 ExR (Excess Red Index)	64 64 67
 das Imagens	64 64 67 71
 das Imagens	64 64 67 71 74
 das Imagens	64 64 67 71 74 77
 das Imagens	64 67 71 74 77 78
 das Imagens	64 64 67 71 74 77 78 79
 das Imagens	64 67 71 74 77 78 79 83
 das Imagens	64 67 71 74 77 78 79 83 84
das Imagens 4.3.1 ExG (Excess Green Index) 4.3.2 ExR (Excess Red Index) 4.3.3 ExG-ExR (Excess Green minus Excess Red Vegetation Index) 4.3.4 MaxG (Maximum Green Index) 4.4 Estimativa do Número de Mudas na Imagem 4.5 Estimativa da Produção de Mandioca da Fazenda 4.6 Discussão dos Resultados 5. CONSIDERAÇÕES FINAIS 5.1 Sugestões para Trabalhos Futuros REFERÊNCIAS BIBLIOGRÁFICAS	64 67 71 74 77 78 79 83 84 86
das Imagens 4.3.1 ExG (Excess Green Index) 4.3.2 ExR (Excess Red Index) 4.3.3 ExG-ExR (Excess Green minus Excess Red Vegetation Index) 4.3.4 MaxG (Maximum Green Index) 4.4 Estimativa do Número de Mudas na Imagem 4.5 Estimativa da Produção de Mandioca da Fazenda 4.6 Discussão dos Resultados 5. CONSIDERAÇÕES FINAIS 5.1 Sugestões para Trabalhos Futuros REFERÊNCIAS BIBLIOGRÁFICAS APÊNDICES	64 67 71 74 77 78 78 83 84 86 94
das Imagens	64 67 71 74 77 78 79 83 84 86 94
das Imagens	64 64 71 71 74 77 78 79 83 84 86 94 95
das Imagens	64 64 71 74 77 78 79 83 84 86 94 94 95 97
das Imagens	64 67 71 74 78 79 83 84 86 94 94 95 97 99

APÊNDICE F	
APÊNDICE H	105
APÊNDICE I	107
APÊNDICE J	109

1. INTRODUÇÃO

A agricultura é uma área em constante desenvolvimento. Desde o início da humanidade, a terra é utilizada para produção de alimentos por meio do emprego de técnicas que se aperfeiçoam com o passar do tempo (CARVALHO, 2011).

Com o contínuo crescimento populacional e a constante disputa por espaço, é fundamental que se consiga extrair o máximo da capacidade da terra, evitando desabastecimento e aumento no custo dos alimentos. Pensando neste tipo de problema, nas últimas décadas foram desenvolvidas técnicas com foco no aumento de produtividade na agricultura, como a utilização de implementos cada vez mais modernos e o desenvolvimento de novos tipos de defensivos agrícolas e sementes transgênicas, que proporcionam à planta uma maior resistência a pragas e doenças e, consequentemente, ampliam a capacidade de produção (SOARES, 2017).

Um novo campo de avanço para agricultura está no emprego de tecnologias de precisão no manejo da lavoura. Com a utilização de recursos de tecnologia da informação é possível realizar a gestão dos processos e o emprego de técnicas de georreferenciamento que possibilitam o monitoramento constante e preciso da cultura (SOARES, 2017).

Conhecida como Agricultura de Precisão (AP), tal segmento tem sido fortalecido desde meados da década de 1990 com o aparecimento do Sistema de Posicionamento Global (ou, em inglês, *Global Positioning System* -GPS) (MANTOVANI, 1998). A AP consiste em um agrupamento de tecnologias voltadas para o manejo do solo, da cultura e dos insumos visando um melhor e mais detalhado gerenciamento do sistema de produção agrícola em todas as etapas, desde a semeadura até a colheita. Com isso, a AP está direcionada à gestão de sistemas de produção agrícola, considerando a variabilidade espacial e temporal para minimizar os efeitos negativos ao meio ambiente e potencializar o retorno econômico. Diante deste fato, passa a ser uma realidade a busca por novas informações aplicadas para atender às novas necessidades do agronegócio (INAMASU, 2011). Os Veículos Aéreos não Tripulados (VANTs) têm sido uma nova alternativa para as demandas rurais. Segundo Jorge e Imenasu (2011), o processo de fortalecimento do desenvolvimento de VANTs aparece como uma importante ferramenta na AP. A sua aplicação na área agrícola favorece atividades complexas e promove novos estudos e desafios para o campo.

De acordo com Jorge e Imenasu (2011), os primeiros relatos de pesquisa com aeronaves não tripuladas no Brasil ocorreram em 1980 no Centro Tecnológico Aeroespacial (CTA) com o desenvolvimento de um projeto utilizado para fins militares, batizado de Acauã. As pesquisas no Brasil podem ser consideradas recentes e os principais trabalhos com VANTs têm como objetivo maior aplicações civis, como vigilância de propriedades, inspeções de redes elétricas, monitoramento de áreas rurais, acompanhamento da produção agrícola e dimensionamento da aplicação de pesticidas e queimadas (MEIDEIROS, 2007).

O Sensoriamento Remoto (SR) é uma tecnologia relativamente recente que consiste em obter informações de uma área localizada na superfície terrestre através de sensores. Com SR pode-se obter geoinformações novas ou iguais às informações obtidas em campo, mas o levantamento remoto reduz o trabalho para percorrer a área e obtêm-se dados da região em menos tempo. A distância do sensor em relação à superfície terrestre sofre uma variação e é classificada em 3 níveis: orbital (sensores acoplados em satélites), aéreos (sensores acoplados em aeronaves) e os terrestres (sensores implantados no campo) (LONGHITANO, 2010).

Em relação ao uso de VANTs para sensoriamento remoto na agricultura de precisão, existem várias possibilidades relatadas por diversos autores: Montalvo (2012), Gonzalez-Dugo (2013), Felix, (2017), Souza (2017) e Lu (2017). Em suma, os trabalhos citados procuraram entender os reais ganhos do uso dos *drones* no sensoriamento remoto para tomada de decisão junto ao produtor rural.

Independentemente da aplicabilidade das aeronaves não tripuladas, a escolha do sensor vai definir se a operação vai ser bem sucedida ou não (SIEBERT e TEIZER, 2014). O mercado oferece uma grande variedade de sensores. A escolha dos sensores nem sempre é fácil, pois gera um problema

2

principalmente para quem está começando a desenvolver trabalhos com sensoriamento remoto. Dependendo do trabalho, pode-se aplicar sensores ópticos (RGB - RED (Vermelho), Green (Verde) e Blue (Azul), infravermelho próximo (NIR - *Near InfraRed*) ou infravermelho afastado (FIR - *Far InfraRed*) (SOUSA, 2017).

1.1 Contexto do problema de pesquisa

Em pequenas e médias propriedades rurais, o processo de monitoramento manual da região requer grande esforço, pois para a geração de dados de precisão do local precisam ser realizados extensos deslocamentos com o corpo técnico para coleta das informações requeridas (SILVA, 2016).

O principal problema é o acesso a informações relevantes no tempo adequado para a tomada de decisão. Como consequência, a demora na tomada de decisão pode provocar prejuízos ao produtor rural (SILVA, 2016).

Mendonça (2011) explica que as imagens geradas por satélites são amplamente utilizadas no processo de monitoramento de regiões agrícolas, mas apresentam alguns pontos negativos para sua utilização, que são a baixa resolução, a impossibilidade de detectar regiões pequenas, a dificuldade no acesso aos dados, o tempo de produção das imagens, entre outros.

A produção nacional da cultura de mandioca, segundo a CONAB, em 2002, foi de 22,6 milhões de toneladas de raízes, numa área plantada de 1,7 milhão de hectares, com rendimento médio de 13,3 t ha . Dentre os principais Estados produtores destacaram-se: Pará (17,9%), Bahia (16,7%), Paraná (14,5%), Rio Grande do Sul (5,6%) e Amazonas (4,3%), que respondem por 59% da produção do País.

O Município de Tucuruí faz parte de uma região que concentra uma grande quantidade de propriedades caracterizadas por serem de agricultura familiar. Na Figura 1 é apresentada a sede da fazenda onde foi conduzida esta pesquisa. A Fazenda Bela Vista tem como sua principal atividade econômica o plantio da mandioca no período chuvoso.



Figura 1 – Sede da Fazenda Bela Vista e a preparação do solo para plantio com queimadas.

A produção agrícola é cultivada pelo fazendeiro e sua família e colhida para consumo próprio. O excedente é vendido nas feiras livres do município (Figura 2). Neste caso, não existe o papel do atravessador no processo de negociação dos produtos.



Figura 2 - Banca do agricultor na Feira Municipal de Tucuruí.

Como característica da região, que são áreas de morro, os desníveis existentes na fazenda propiciam a criação de peixes (piscicultura). Portanto, além da produção agrícola, a propriedade também comercializa peixes do tipo *Tilápia*. A Figura 3 exibe um modelo tridimensional da sede da fazenda, onde é possível visualizar os desníveis e o reservatório de peixes próximo a ela.



Figura 3 - Reservatório de criação de Tilápias.

1.2 Justificativa

As fotografias aéreas em geral são produzidas através de veículos aéreos tripulados e satélites. A principal desvantagem do uso de imagens por satélite é o alto custo do serviço para pequenas e médias propriedades (JORGE, 2002).

De acordo com pesquisas recentes é possível utilizar VANTs na agricultura familiar para aquisição de dados por sensoriamento remoto, como pode ser observado na Tabela 1 a seguir. As imagens podem ser utilizadas para auxiliar o agricultor nas várias etapas do manejo agrícola.

Na contratação de serviços gerados por VANTs os custos são reduzidos, pois para veículos aéreos não tripulados a presença de um operador humano a bordo não é necessária. Com a miniaturização dos componentes, esses equipamentos podem ser utilizados em diversas áreas e seguem as mesmas condições de operação de aeronaves convencionais só que de tamanho reduzido (JORGE, 2002).

Com a redução do custo dos VANTs recentemente, o pequeno e médio agricultores podem se beneficiar com o emprego desta tecnologia para

auxiliar o proprietário da plantação com informações suficientes para a tomada decisão em seu agronegócio.

Tabela 1 – Áreas potenciais do emprego de VANT na agricultura de precisão

Gestão em agronegócio
Monitoramento de safras e suas faces
Gestão da produção em diferentes culturas
Prospecção de logística da produção
Estimativa da produção
Segurança agrícola
Mapeamento ambiental
Mapeamento de área plantada
Construção de mapas em 3D da plantação
Monitoramento do rebanho
Detecção de falhas no plantio
Estresse hídrico (falta de água na plantação)
Nutrição da plantação

Fonte: Adaptação de Chiacchio (2017).

A aplicação de técnicas de processamento digital de imagens e visão computacional em imagens capturadas por VANTs tem se destacado como uma ferramenta promissora neste contexto.

O agricultor enfrenta dificuldades em quantificar a safra de sua plantação, portanto, esta pesquisa busca responder o seguinte questionamento:

Como é possível estimar a produção agrícola com técnicas de Visão Computacional em imagens capturadas por um VANT?

1.3 Objetivos de Pesquisa

Este é um estudo exploratório que pretende compreender o potencial do uso de imagens capturadas por um VANT de pequeno porte para auxiliar na estimativa da produção de uma cultura de mandioca de uma fazenda de agricultura familiar, que é bastante comum na região estudada.

Portanto, o objetivo geral desta pesquisa é estimar a produção de uma lavoura de mandioca através da aplicação de técnicas de Visão Computacional apropriadas para o contexto de agricultura familiar no Município de Tucuruí através de imagens capturadas por um VANT de asas rotativas (multirrotor).

1.3.1 Objetivos Específicos

De maneira mais específica, esta pesquisa pretende:

- Fazer a aquisição de imagens através de um VANT de pequeno porte no local de estudo;
- Realizar o pré-processamento das imagens;
- Aplicar índices de vegetação nas imagens;
- Realizar a segmentação das imagens resultantes;
- Realizar o tratamento das imagens segmentadas;
- Avaliar as imagens para fazer a contagem de mudas nas imagens segmentadas e a estimativa da produção do agricultor.

1.4 Métodos de pesquisa

Para alcançar os objetivos desta dissertação alguns passos foram adotados. O primeiro passo foi um levantamento bibliográfico sobre aplicações de VANTs na agricultura de precisão e no sensoriamento remoto; conceitos relevantes de PDI; fundamentos das imagens digitais; técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola; e trabalhos relacionados.

O segundo passo envolve a definição da área de estudo em conjunto com o agricultor. O terceiro passo é a preparação, planejamento e uso materiais da pesquisa. Já o quarto passo corresponde aos procedimentos metodológicos utilizados para se conduzir esta pesquisa exploratória.

De posse dos resultados, esta pesquisa buscou discuti-los com referências que pudessem explicar o significado do que foi descoberto. Como característica de estudos exploratórios, procuramos contribuir para o levantamento de novas hipóteses de pesquisa.

1.5 Contribuições desta pesquisa

Esta pesquisa provê uma investigação detalhada de como se alcançou os resultados com os índices de vegetação aplicados às imagens. Como contribuição científica, este estudo aponta que, dentre os índices de vegetação aplicados, o MaxG não foi muito citado na literatura, teve o melhor resultado para o contexto da imagem em estudo, contando 91% das mudas com uma acurácia de 70%.

Também foi possível concluir que, no nosso caso, o índice de Excesso de Vermelho (ExR) é mais apropriado para a contagem das mudas em estágios iniciais de germinação. Já o índice da diferença do Excesso de Verde com o Excesso de Vermelho (ExG-ExR) pode possibilitar a estimativa automática da produção através da criação de sistemas de VC com limiarização não supervisionada.

Nas etapas da VC, é importante considerar: (1) a aplicação de mais técnicas de pré-processamento nas imagens, como contraste e brilho; (2) a aplicação de índices de vegetação que independam de definição de limiar no histograma, pois no estudo em questão foram os que melhor separaram a vegetação do fundo; (3) o uso de técnicas de separação de mudas conectadas após a etapa de segmentação das imagens. Estes aspectos tornaram a estimativa da produção de plantas mais assertiva.

Como contribuições práticas para o agricultor, este estudo possibilitou a conscientização da importância de prever a estimativa da colheita para melhor planejar a negociação da produção, os plantios posteriores e a busca por recursos para aumentar a área mecanizada da cultura. Também foi possível perceber a necessidade de preparar as linhas de plantio, de melhorar o preparo do solo e a irrigação.

Mesmo não oferecendo alta precisão na contagem de mudas e, consequentemente, na estimativa da produção, foi possível perceber, neste estudo exploratório, que a assertividade da estimativa da produção agrícola depende também da consideração de fatores influenciadores, como a irrigação do solo, a distância entre as mudas e as linhas de plantio.

A comparação dos estágios da planta com a produtividade da colheita também pode melhorar a compreensão dos fatores que influenciam na

8

assertividade da estimativa de um sistema de VC no contexto de agricultura familiar.

Por fim, os códigos do projeto foram compilados e disponibilizados nos Apêndice A a G para a criação de uma toolbox (caixa de ferramentas computacional) em MATLAB para auxílio a futuras pesquisas de Visão Computacional aplicadas à agricultura. Este tipo de conhecimento não é facilmente encontrado na literatura e pode contribuir para aumentar o uso desta tecnologia no contexto da agricultura familiar.

1.6 Organização do trabalho

Este documento está dividido em cinco capítulos, os quais abordam os assuntos e os temas identificados na definição dos objetivos apresentados anteriormente. Depois deste capítulo introdutório, o Capítulo 2 apresenta, fundamentação teórica do uso dos VANTs como ferramenta na agricultura de precisão e no sensoriamento remoto, dos conceitos de Processamento Digital de Imagens e Visão Computacional, das principais técnicas de PDI, VC e Tecnologias de SR aplicadas ao contexto agrícola e dos estudos recentes de estimativa de produção agrícola com imagens.

O Capítulo 3 apresenta a metodologia utilizada para a execução deste estudo. Este capítulo mostra a área de estudo, os materiais utilizados, os procedimentos metodológicos e as ameaças à validade do estudo.

O Capítulo 4 apresenta a análise dos resultados provenientes da aquisição das imagens, do pré-processamento das imagens, do processo de aplicação dos índices de vegetação, da estimativa do número de mudas de mandioca e a estimativa da produção desta cultura na Fazenda.

No Capítulo 5 são apresentadas as conclusões do trabalho e as sugestões para trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos fundamentais referentes ao uso de VANTs como ferramenta na agricultura de precisão e no sensoriamento remoto, as principais técnicas de um Sistema de Visão Artificial (SVA) e SR aplicadas ao contexto agrícola, e os trabalhos relacionados voltados ao acompanhamento do processo de plantio até a colheita, bem como especificamente a contagem da população de plantas de culturas agrícolas.

2.1 Uso de VANTs na agricultura de precisão e no sensoriamento remoto

A criação dos VANTs surgiu como uma importante ferramenta para a agricultura de precisão¹, sua utilização na área agrícola vem crescendo de acordo com o avanço tecnológico percebido, com a redução do tamanho dos equipamentos, com a redução de seus custos e com a melhoria da sua operabilidade (CHIACCHIO, 2017).

Nas plantações, a utilidade de VANTS se dá principalmente na otimização da produção. Os Estados Unidos surgiram como um dos líderes em termos de fabricação e utilização destas máquinas, junto com Israel. O Japão se destaca com mais de 2000 VANTs utilizados na agricultura de precisão com destaque na pulverização e missões de reconhecimento (JORGE e INAMASU, 2014).

A Associação Internacional de Veículos Aéreos Não Tripulados (*Association for Unmanned Vehicle Systems International* – AUVSI) prevê a geração de mais de 100 mil postos de trabalhos, gerando um impacto na economia americana de 82 milhões de dólares, isto só para as décadas de 2015 a 2025 (AUVSI, 2013).

O principal fator que sustenta este crescimento são os benefícios que esta tecnologia pode trazer para a indústria e à agricultura. Isto se deve à miniaturização de componentes e à aplicação desta tecnologia em operações civis. Os *drones* deixam de ser um produto estritamente militar e começam a ser utilizados pelo público em geral integrando o cotidiano das pessoas e das empresas (SOUSA, 2017).

¹Uso de tecnologias para o acompanhamento das áreas agrícolas.

O uso de sensoriamento remoto por meio de imagens de satélites apresenta alguns problemas. Um deles é obter imagens em um curto espaço de tempo gerando assim a falta de integração com sistemas de produção agrícola. Esta incerteza do prazo gera uma falta de confiança no retorno financeiro dessa aplicação. Uma solução para este problema é a utilização de VANTs de pequeno porte e fácil operabilidade para se obter uma resposta mais rápida em relação às informações obtidas pelo sensoriamento remoto (TIAN, 2017).

Existem vários modelos de VANTs em uso no mercado, assim como também vários modelos de sensores que podem ser aplicados a este tipo de equipamento. A gama de sensores utilizados no mercado varia de sensores espectrais de banda visível até sensores hiperespectrais, multiespectrais até próximo ao infravermelho. São usados também sensores de localização para planejamento de rotas em conjunto com a unidade de armazenamento para salvar as imagens obtidas durante o voo. Neste trabalho iremos concentrar a nossa pesquisa em sensores acoplados aos VANTs.

Os dois principais tipos de VANTs são: os multirrotores e os de asa fixa. Os dois tipos são utilizados para o levantamento de informações geoespaciais, mas cada um obedecendo a sua arquitetura e capacidade (LONGHITANO, 2010).

Segundo Moutinho (2015), os VANTs do tipo multirrotores são os mais indicados para trabalhos arquitetônicos de fotometria por decolarem de forma vertical em espaços confinados. Já os de asa fixa são voltados para serviços que exigem o sensoriamento de grandes áreas com vôos mais longos. Estes VANTs são indicados para agricultura de precisão.

Os principais tipos de sensores de imagem utilizados pelas aeronaves não tripuladas na agricultura são os sensores na faixa do visível (RGB), os sensores infravermelhos (IV) e infravermelho termal.

Os sensores que atuam na coleta de imagens na faixa de frequência visível ao olho humano são utilizados na agricultura de precisão e

sensoriamento remoto para a geração das chamadas imagens georeferenciadas.

O georreferenciamento é uma tecnologia de grande importância, pois insere os dados feitos no mapeamento e coloca essas informações no mundo real. Isso possibilita a visualização do mapa com as medições encontradas na área levantada. No aerolevantamento com *drones*, o georreferenciamento é a associação de cada *pixel* da imagem com uma região física da área a ser coletada, baseada em um Sistema de Geodésico de Referência (SOUSA, 2017).

Para se obter uma imagem com georreferenciamento dos dados, o sistema de processamento das imagens terá que obter as coordenadas de um pequeno número de pontos visivelmente identificáveis nas imagens. No mapeamento utilizando os VANTs, essas coordenadas se referem aos pontos de controles no solo, conhecidos como GCP - Ground Control Points (SOUSA, 2017).

Uma revisão recente sobre o estado da arte da integração de VANTs com sistemas de imagens para melhorar as capacidades de fenotipagem no campo revela o uso desta tecnologia para várias atividades realizadas no campo, como avaliação da proliferação, do vigor e da caracterização do potencial de crescimento das plantações (SANKARAN et al., 2015).

O tipo de sensor mais utilizado, mostrado na Tabela 2, em VANTs são os sensores RGBs, pois estes sensores trabalham mais na faixa de frequência visível ao olho humano. Eles podem ser encontrados nas câmeras mais comuns ou nas mais profissionais. Os infravermelhos, multiespectral, hiperespectral e o termal são utilizados de acordo com o projeto, pois esses sensores estão dentro uma faixa espectral diferente da visível (MUNARETTO, 2015).

Outro tipo de sensor voltado para aeronaves não tripuladas é o LIDAR (*Light Detection And Ranging* – Detecção na Mudança de Luz). Esse sensor emite pulsos de luz (laser) para medir a distância do objeto e sua altura. Suas aplicações estão voltadas para a geração de imagens 3D, gera o cálculo

de volumes, a topografia da área, entre outras aplicações. A Figura 4 mostra o sensor Velodyne HDL-32e acoplado a um VANT.

Tipo do sensor	Informação registrada	Referência	Uso	Câmera
Visível	Obtém informações nas regiões espectrais do Azul, do Verde e do Vermelho.	Câmera DJI Fonte: DJI PHANTOM 4 (2018)	Obras, agricultura e mineração.	
Visível + Infravermelho	Obtém informações em duas regiões espectrais: visível (Azul, Verde ou Vermelho) e o infravermelho próximo.	Tetracam ADC Lite Fonte: TETRACAM (2018)	Estresses, hídricos (falta de água na plantação) e biomassa.	
Multiespectral	Obtém informações em três ou mias regiões espectrais: visível infravermelho próximo e médio.	Tetracam Mini MCA Fonte: TETRACAM (2018)		
Hiperespectral	Obtém informações em muitas regiões espectrais do visível e infravermelho (próximo e médio).	Rikola Fonte: Senop (2018)		
Termal	Obtém informações na região do infravermelho distante, isto é, espectro termal.	Wiris Fonte: Workswell (2018)		

Tabela 2 - Tipos de sensores acoplados em VANTs para sensoriamento remoto

Fonte: Adaptação de Linhares (2016).



Figura 4 – Sensor Velodyne HDL-32e, opção LIDAR para VANT. Fonte: Imagens retiradas do site do fabricante (VELODYNE LIDAR, 2018).

2.2 Conceitos relevantes de Processamento Digital de Imagens (PDI)

Ao fazer a revisão de PDI e VC é possível perceber que estas áreas possuem conceitos que convergem em alguns aspectos e parecem fazer uma intersecção entre si: (SCHALKOFF, 1989); (GONZALEZ e WOODS, 1992); (CASTLEMAN, 1995); (JAIN ET AL., 1995) e (MARQUES FILHO e VIEIRA NETO, 1999). Essas etapas são: o pré-processamento, a segmentação e a extração de características de uma imagem (SOARES, 2017).

Apesar disso, ambas as áreas possuem focos distintos: PDI tem o objetivo de utilizar técnicas computacionais de aperfeiçoamento de imagens para a interpretação humana, enquanto que VC tem como foco a análise automática utilizando o computador para extrair informações de uma cena, simulando funções cognitivas humanas (SCHALKOFF, 1989) (JAIN et al., 1995). Assim, PDI procura melhorar o aspecto visual de imagens em termos de qualidade e nitidez para a análise e interpretação humana e VC busca automatizar esta análise fornecendo ao computador capacidade visual próxima à de seres humanos (MARQUES FILHO e VIEIRA NETO, 1999).

Um sistema de PDI é composto de elementos de aquisição de imagens, como câmeras; de processamento de imagens, que envolve a utilização de técnicas e algoritmos computacionais para melhorar ou modificar as imagens digitais; de estruturas de armazenamento de imagens digitais, como discos ópticos; e de saída, como monitores de vídeo. A Figura 5 exibe a disposição dos elementos citados.



Figura 5 – Elementos de um sistema de PDI. Adaptado de (MARQUES FILHO e VIEIRA NETO, 1999).

Por outro lado, um sistema de VC tem o objetivo de fazer a aquisição, o processamento e a interpretação de imagens relacionadas a cenas da realidade (SCHALKOFF, 1989). Este tipo de sistema possui a disposição das etapas do processo conforme a Figura 6 e é composto de:

- a) Domínio do Problema: corresponde ao problema a ser resolvido e seu contexto.
- Aquisição da imagem: etapa que consiste em adquirir as imagens relacionadas à cena a ser analisada.
- c) Pré-processamento: etapa que procura corrigir imperfeições, como, por exemplo, ruídos, contraste inadequado e objetos indevidamente conectados;
- d) Segmentação: etapa que busca dividir a imagem em unidades significativas que compartilham características entre si para o reconhecimento de objetos;
- e) Extração de Características: etapa que objetiva extrair características das imagens segmentadas;

- f) Reconhecimento e Interpretação: etapa que atribui significado aos objetos reconhecidos;
- g) Base de conhecimento: é o repositório que armazena o conhecimento sobre o problema a ser resolvido e que, idealmente, deveria realimentar as etapas anteriores, conforme a evolução do conhecimento sobre a resolução do problema em questão.
- h) Resultado da análise: corresponde à consequência das etapas anteriores.





Nas imagens brutas provenientes de SR é possível aplicar técnicas para facilitar a identificação, o realce e a extração de informações contidas nas imagens, para posteriormente realizar a interpretação do significado dos resultados. Isto envolve o reconhecimento de padrões e a partir dos resultados, outras imagens são produzidas com informações específicas a serem interpretadas pelo computador. A informação de interesse é caracterizada em função das propriedades dos objetos ou padrões que compõem a imagem (SILVA, 2001).

2.3 Fundamentos das imagens digitais

O Processamento de Digital de Imagens é uma área multidisciplinar constituídas por várias ciências como: Física, Matemática, Álgebra, Estatística, Computação, entre outras. Essas áreas são de fundamental importância para um projeto de sistema de processamento de imagem. Existe também a correlação do PDI com as disciplinas: Rede Neurais, Inteligência Artificial, Percepção Visual e Ciências Cognitivas (DE QUEIROZ, 2006).

2.3.1 Modelo RGB

A cor é um elemento primordial para a interpretação da visão humana. Os objetos que emitem luz visível são percebidos em função da soma das cores espectrais emitidas. O processo de formação das cores é denominado aditivo. O aditivo pode ser entendido como uma combinação da radiação monocromáticas nas faixas espectrais associadas às sensações de cores verde, vermelho e azul, as quais são responsáveis pela formação de todas as demais sensações de cores registradas pela visão humana. As cores verde, vermelho e azul são ditas cores primárias. Este processo gerou um modelo cromático denominado *RGB (Red, Green, e Blue)* apresentado na Figura 7 (BATISTA, 2005).



Figura 7 – Processo de formação de cores aditivo (RGB).

Uma cor no sistema RGB é um vetor no espaço tridimensional representada por suas coordenadas (r, g, b) denominado espaço RGB. No espaço RGB, a reta definida pelo conjunto de pontos (*i*, *i*, *i*) é chamada de reta acromática. Pontos sobre a reta acromática representam tonalidades de cinza, ou níveis de cinza, variando continuamente do preto ao branco esta forma, a medida que percorremos a reta a partir da origem. O ponto (0, 0, 0) representa o preto (ausência de luz). Um ponto (C, C ,C), onde C é a intensidade máxima que pode assumir qualquer componente de cor, representa o branco. A Figura 8 mostra o espaço de cores RGB (BATISTA, 2005).



Figura 8 – Espaço de cores em RGB.

2.3.2 Imagem digital

Uma imagem monocromática é representada por uma função com duas dimensões continuas f(x, y) onde $x \in y$ são coordenadas e o valor de f esta representado para qualquer ponto em (x, y) esta relação é proporcional a intensidade luminosa, brilho ou nível de cinza, no ponto escolhido. Para o processamento de imagens como os computadores não conseguem processar imagens continuas, apenas vetores contendo números digitais, isto é, deve-se representar a imagens como arranjos bidimensionais de pontos. Cada ponto dessa imagem vai ter um elemento chamado de *pixel*. A Figura 9 mostra a representação de uma imagem bidimensional (BATISTA, 2005).





As imagens coloridas no modelo RGB é representada por um vetor formado por três componentes que representam as intensidade das cores vermelho, verde e azul. Para formação de uma imagem resultante da composição de três planos monocromáticas $f(x, y) = f_R(x, y) + f_G(x, y) + f_B(x, y)$ mostrados na Figura 10 (DE QUEIROZ, 2006).



Figura 10 – Representação de uma imagem digital bidimensional.

2.3.4 Amostragem e Quantização

Uma imagem para ser processada por um computador deve ser digitalizada em dois componentes: *espacial* e *amplitude*. A digitalização ou discretização da componente espacial é realizada por um processo chamado de *amostragem* que é a representação da imagem na forma mais simples, isto é, uma função continua e finita (DE QUEIROZ, 2006). A discretização dos valores de brilho denomina-se *quantização* e corresponde a transformação de

uma função continua de amplitude, isto é, uma quantidade limitada de níveis de cinza. A matriz RxC resultante do processo de discretização espacial e de brilho representa uma imagem digital monocromática, e cada elemento f(i,j) é conhecido por *pixel* (BATISTA, 2005).

$$\begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0,C-1) \\ f(1,0) & f(1,1) & \cdots & f(1,C-1) \\ \cdots & \cdots & \cdots \\ f(R-1,0) & f(R-1,1) & \cdots & f(R-1,C-1) \end{bmatrix}$$

Representação de uma imagem monocromática que apresenta unicamente gradações de cinza, com *pixels* mais claros representando valores mais elevados; *pixels* pretos têm valor zero. A Figura 11 mostra a imagem monocromática a representação matricial correspondente.





2.3.5 Fotogrametria (aerofotogrametria)

Antes de definir uma fotogrametria deve-se determinar primeiramente o que é uma imagem fotográfica área. Uma imagem fotográfica segundo Ray (1963), consiste em um registro instantâneo de um terreno mostrando os seus detalhes. Isso ocorre principalmente pela distancia focal da lente da câmera, pela altura do voo do avião no momento da exposição para capturara da imagem, pelo tipo de filme e filtros usados. As imagens áreas estão relacionadas geometricamente com o tipo de câmera utilizada. As fotografias aéreas podem ser tiradas na forma vertical ou oblíqua. No contexto
deste trabalho as fotos áreas foram tiradas de forma vertical (eixo da câmera apontada para baixo) mostrado na Figura 12 (TEMBA, 2000).



Figura 12 – Imagens área retirada na posição vertical.

A partir da definição de fotos áreas a fotogrametria se utiliza destas imagens aplicando medições através de pontos de posicionamento relativos. Com isso podemos fazer o recobrimento, que é a representação da área através de imagens aéreas, as quais são tiradas sucessivamente, ao longo de uma direção de voo (TEMBA, 2000). Essa sucessão é feita em intervalo de tempo tal que, entre duas imagens haja uma superposição longitudinal de cerca de 60% e uma superposição lateral de 30% entre as faixas mostrado na Figura 13. Esta tecnologia cria então imagens 3D com base em imagens 2D podendo gerar os seguintes artefatos de medida: distâncias, áreas, volumes, elevações, tamanhos e formas de objetos (REDWEIK, 2007).



Figura 13 – Fotogrametria recobrimento lateral 30% longitudinal 60%.

2.4 Principais técnicas de PDI, VC e tecnologias de SR aplicadas ao contexto agrícola

No contexto agrícola têm sido aplicadas técnicas específicas de PDI, VC e utilizado tecnologias de SR para a solução de problemas relacionados às propriedades, comportamento e desenvolvimento de culturas no campo (MEYER e CAMARGO NETO, 2008).

2.4.1 Índices de vegetação

O uso de índices de vegetação no SR não é algo novo. Há muitos estudos usando diferentes bandas espectrais e combinações de índices de vegetação (MEYER e CAMARGO NETO, 2008).

Na avaliação de coberturas vegetais, como a identificação de espécies, de medidas, de biomassa e de estresse hídrico de plantas, têm sido utilizados índices de vegetação aplicados à medições espectrais². Como resultado, as áreas avaliadas apresentam uma mistura complexa de vegetação, brilho, cor e umidade do solo, efeitos ambientais, sombras, entre outros. Estes índices também são afetados por variações espaços-temporais da atmosfera, como o clima (BANNARI et al., 1995).

Mais de 50 índices foram desenvolvidos nas últimas décadas e a maioria deles tem sido usada em imagens capturadas com tecnologia de infravermelho próximo (NIR - *Near Infrared*) pela sua eficácia em detectar a presença de vegetação verde (BANNARI et al., 1995). A radiação visível no vermelho (630-690 nm) é absorvida pela clorofila, enquanto que a radiação no infravermelho próximo (760-900 nm) é fortemente refletida pelas estruturas celulares das folhas. Ao examinar a curva geral de refletância da vegetação, o desvio observado entre o vermelho e o infravermelho próximo constitui uma variável sensível à presença de vegetação verde. A resposta espectral da vegetação no vermelho está fortemente correlacionada com a concentração de clorofila, enquanto que a resposta espectral no infravermelho próximo é

² Medida espectral é uma função definida em certos subconjuntos de um conjunto fixo no qual todos os valores possíveis são operadores autoadjuntos no espaço de *Hilbert* (https://pt.wikipedia.org/wiki/Medida espectral Acessado em 02/07/18).

controlada pelo índice de área foliar e densidade de vegetação verde (MAJOR et al., 1990).

Apesar de sua eficácia, esta tecnologia apresenta custos elevados quando utilizada em áreas menores, como é o contexto agrícola de pequeno a médio porte. Outros índices de vegetação baseados em cores utilizam somente as bandas espectrais verde, vermelho e azul. A vantagem de usar índices de cores é que eles acentuam uma cor particular, como o verde das plantas. Portanto a utilização de VANTs com câmeras digitais de alta resolução possibilita a aquisição de imagens áreas com alta resolução. (LUCIEER et al., 2014). Ao mesmo tempo, com o surgimento do software baseado em estrutura por movimento (SfM - *Structure from Motion*) (Verhoeven, 2011), foi possível criar nuvens de pontos 3D e ortofotos com altos níveis de detalhes (BENDIG et al., 2015). Hunt e colaboradores (2014) demonstram como é calculada a banda visível de índices de vegetação em RGB a partir de ortofotos.

No contexto da agricultura familiar, imagens convertidas em canais RGB capturadas por VANTs têm proporcionado uma alternativa mais simples e de baixo custo para a aplicação de índices de vegetação (MEYER E CAMARGO NETO, 2008). Os índices de banda visível RGB mais utilizados para avaliar a cobertura vegetal são GRVI (*Green Red Vegetation Index*) (TUCKER, 1979) e suas adaptações, como por exemplo, MGRVI e RGBVI (BENDIG, et.al, 2015); ExG (*Excess Green Index*) (WOEBBECKE et al., 1995); ExR (*Excess Red Index*); ExG – ExR (*Excess Green minus Excess Red Vegetation Index*); e MaxG (*Maximum Green Index*). A seguir, cada um deles é explicado.

2.4.1.1 GRVI (Green Red Vegetation Index)

O índice GRVI explora a alta refletância das plantas no verde (cerca de 540 nm) e a absorção na parte vermelha e azul do espectro visível (400-700 nm) através das clorofilas das plantas (TUCKER, 1979).

Sua equação é dada por:

$$GRVI = (g-r)/(g+r)$$
(1)

Onde r e g são os valores digitais normalizados de R e G, de acordo com as equações 2 e 3.

$$r = R/(R+G+B)$$

$$g = G/(R+G+B)$$
(2)
(3)

Em que R e G são os valores digitais de cada *pixel* das imagens coloridas nos canais vermelho e verde, respectivamente.

Na sua interpretação, o valor resultante do índice considera um intervalo de valores de -1 a +1 (TUCKER, 1979). Quanto ao equilíbrio entre a refletância verde (comprimentos de onda de 500-570 nm) e refletância vermelha (comprimentos de onda de cerca de 620 a 700 nm), é possível encontrar três grupos de padrões de refletância espectral para os principais componentes da cobertura do solo:

Vegetação verde (coníferas, árvores e grama)
 quando *g* é maior que *r*.

• Solos (areia, sedimentos e argila seca) quando *g* é menor que *r*.

Água ou neve quando g e r são praticamente os mesmos.

Este índice tem sido usado como um indicador de fenologia³ e tem potencial para estimativa de biomassa (MOTOHKA et al., 2010). Perez et al. (2000) usou os canais verde e vermelho para separar plantas de solo e resíduos em fundo de imagens. Chamard e colaboradores (1991) consideram este índice útil para identificar e mapear vegetação em regiões inundadas.

A verificação de falhas nas linhas de plantio é outra utilização importante de VANTs nos sistemas agrários. De Souza (2017) utilizou um método que se mostrou eficiente para a estimativa dos saltos em uma plantação de cana de açúcar. A metodologia utilizada para este trabalho foi

³ Ramo da Ecologia que estuda os fenômenos periódicos dos seres vivos e suas relações com as condições do ambiente, tais como temperatura, luz e umidade. A migração das aves e a floração e frutificação de plantas são exemplos de fenômenos cíclicos estudados pela fenologia.

dividida em três etapas: a primeira etapa do estudo foi identificar as linhas de colheita. Esse passo foi necessário para saber se as linhas de colheita estavam disponíveis. Para identificar as linhas de colheita, foi utilizado o Índice de Vegetação da Diferença Normalizada (Normalized Difference Vegetation Index - NDVI), a segunda etapa desenvolveu uma classificação da cana de açúcar e os erros das linhas da colheita foram corrigidos usando o ArcGis. Na terceira e última etapa foi criado um processo utilizando o "ModelBuilder" do software ArcGis para extrair automaticamente as linhas de falhas da plantação. As informações obtidas foram úteis para tomadas de decisão junto ao monitoramento agrícola, tendo como consequência uma redução dos custos operacionais no processo. Os resultados obtidos contribuíram para manter a longevidade e a produtividade da plantação em ciclos sucessivos. O objeto OBIA foi de suma importância para resolver problemas complexos relacionados com as imagens obtidas pelo VANT. A combinação desta tecnologia com outras plataformas de sistemas de informações geográficas, demonstram um avanço na extração e interpretação de informações de sensoriamento remoto.

Recentemente, Bending e colaboradores (2015) propuseram dois índices baseados no GRVI, denominados MGRVI (Modified Green Red Vegetation Index) e RGBVI (Red Green Blue Vegetation Index).

O índice MGRVI é definido como a diferença normalizada da refletância do verde ao quadrado e a refletância do vermelho ao quadrado (BENDIG et al., 2015).

Sua equação é dada por:

$$MGRVI = (g^2 - r^2)/(g^2 + r^2)$$
(4)

Onde r e g são os valores digitais normalizados de R e G, de acordo com as equações 2 e 3, em que R e G são os valores digitais de cada *pixel* das imagens coloridas nos canais vermelho e verde, respectivamente.

Já o índice RGBVI foi introduzido para capturar as diferenças de refletância entre a clorofila de absorção-a (420, 490 e 660 nm) e clorofila de absorção-b (435, 643 nm) (KUMAR et al., 2001). Este índice é definido como

a diferença normalizada da refletância do verde ao quadrado e o produto da refletância azul pela refletância do vermelho.

Sua equação é dada por:

$$RGBVI = g^{2} - (b.r)/g^{2} + (b.r)$$
(5)

Onde r, g e b são os valores digitais normalizados de R, G e B, de acordo com as equações 2, 3 e 6.

$$b = B/(R + G + B)$$
(6)

Em que *R*, *G* e *B* são os valores digitais de cada *pixel* das imagens coloridas nos canais vermelho, verde e azul, respectivamente.

Para ambos os índices modificados, estes autores demonstraram que suas aplicações são limitadas ao estágio de crescimento das culturas. Eles encontraram altas correlações positivas no estágio inicial das plantas, o que é importante para auxiliar no manejo de fertilização e, assim, melhorar o rendimento da cultura.

2.4.1.2 ExG (Excess Green Index)

Também com a intenção de destacar a vegetação em relação ao outros elementos da imagem, como, por exemplo, solo ou pedras, Woebbecke e colegas (1995) propuseram o índice de excesso de verde (ExG – Excess Green) e descobriram que este índice forneceu uma imagem de intensidade quase binária delineando de maneira satisfatória uma região de interesse com vegetação. As regiões vegetais de interesse passaram por um processo de binarização, que consiste em separar uma imagem em regiões de interesse e não interesse através da escolha de um ponto de corte ou limiar selecionado para cada conjunto de imagens (WOEBBECKE et al 1995).

Este índice tem sido amplamente citado e usado em estudos recentes (BENDIG et al., 2015; SONNENTAG, 2012; MEYER e CAMARGO NETO, 2008; MAO et al., 2003; GILTELSON et al., 2002; LAMM et al., 2002; e outros).

Sua equação é dada por:

$$ExG = 2 * g - r - b \tag{7}$$

Onde r, g e b são os valores digitais normalizados de R, G e B, de acordo com as equações 2, 3 e 6, em que R, G e B são os valores digitais de cada *pixel* das imagens coloridas nos canais vermelho, verde e azul, respectivamente.

O uso de VANTs na agricultura permite o acompanhamento do processo de plantio até a colheita. Montalvo (2012) realizou um mapeamento de ervas daninhas em uma plantação de milho. A estratégia do referido autor foi baseada em três processos principais, que foram a segmentação das imagens; a aplicação de duplo limiar com base na abordagem do método de Otsu (OTSU, 1979); e o uso de regressão linear de mínimos quadrados para a equação de computação associadas a linhas de colheitas identificadas.

As imagens foram capturadas no modelo de cores RGB e transformadas em imagens em escalas de cinza, utilizando o índice de vegetação ExG - *Excess Green*. Depois dessa transformada, Montalvo aplicou o método Otsu para separar as ervas daninhas do resto da plantação. A regressão linear de mínimos quadrados foi aplicada para a detecção e ajuste das linhas de corte.

Nos testes foi usada uma grande quantidade de imagens e a superação da regressão linear foi igual ao clássico método do Hough. A Transformada de Hough é um algoritmo utilizado para encontrar formas geométricas, como linhas e círculos em imagens binárias, mesmo em situações de ruído ou de retas incompletas (LI, 2010). Este processo deu origem a um modelo de restrições geométricas, o qual foi utilizado por um sistema de visão computacional para a realização do mapeamento das ervas daninhas na plantação.

Outro uso desta tecnologia é no planejamento da irrigação e da ocupação do solo. O trabalho de Gonzalez-Dugo e seus colaboradores (2013) procurou avaliar a precisão das imagens térmicas tiradas por um VANT no

período da noite para caracterizar as variações do estresse hídrico das espécies plantadas em pomar.

A temperatura da copa das árvores foi extraída usando um método automatizado baseado em objetos para obter a segmentação das imagens. Após a segmentação das imagens foi aplicado um algoritmo desenvolvido no QuantaLab / IAS-CSIC (GONZALEZ-DUGO et al, 2013) usado para restringir as regiões de interesse de cada copa de árvore e excluir as bordas. Somente as partes centrais das imagens foram utilizadas no processamento. Foi utilizado também o Índice de Estresse Hídrico da Cultura (CWSI - Crop Water Stress Index), o qual facilita a interpretação dos dados térmicos da plantação.

Os resultados obtidos neste trabalho demonstraram que as imagens térmicas adquiridas tiveram uma resolução suficiente para demonstrar o estado da água em cada árvore. A análise de variabilidade demonstrou que os dados obtidos às 13 horas eram mais adequados para mostrar a variação de temperatura no pomar. O índice CWSI foi calculado para este novo período. A metodologia proposta pelos referidos autores permitiu a determinação do índice CWSI para todo o pomar levando em consideração as espécies de árvores plantadas.

Já a pesquisa realizada por Felix (2017) visou mapear uma cobertura vegetal localizada no Município de Lavras em Minas Gerais com uma área de aproximadamente 10 hectares da fazenda Muquém, no Centro de Desenvolvimento Científico e Tecnológico na Agropecuária (CDCT) da Universidade Federal de Lavras (UFLA). O estudo foi separado em três etapas.

Na primeira foi utilizado um VANT Phantom 3 com sensor embarcado de modelo Sony EXMOR ½.3" permitindo capturar imagens 3,53 cm / *pixel* com cores reais nos canais RGB. As imagens capturadas nesta etapa foram processadas no software Agisoft Photoscan.

Na segunda etapa foram capturadas novas imagens com o VANT com 150 pontos demarcados na área experimental, resultando na seguinte classificação: vegetação nativa, vegetação de regeneração, pasto, várzea, solos expostos. As imagens capturadas nesta etapa foram processadas pelo software ArcGIS 10.1. Foram avaliados quatro índices de vegetação: Canal Verde Menos Canal Vermelho – (*Green Channel Minus Red Channel* - GMR) (WANG, 2013), Excesso de Verde (ExG - *Excess Green*) (WOEBBECKE,1995), *Kindex* (KI) (KAWASHIMA, NAKATANI,1998) e o Índice de Diferença Normalizado - *Normalized Difference Index* - NDI (MAO, 2003). Estes índices foram utilizados para classificar a cobertura vegetal.

Na terceira e última etapa, foram quantificados os intervalos da reflectância específica para cada cobertura vegetal e foi verificado o mais efetivo no mapeamento da área. Assim, o índice GMR apresentou um resultado mais elevado 25,o KI 0,57, o NDI com 0,31 e o ExG 0,08 em geral todos os índices apresentaram discordância na classificação da cobertura vegetal. Para se ter um resultado melhor desse levantamento teria de acoplar uma câmera com infravermelho no VANT dando um maior espectro de comprimento de onda.

2.4.1.3 ExR (Excess Red Index)

De acordo com Meyer et all (1999) inspirado no fato de que existem 4% de azul, e 32% verde, comparado com 64% de cones vermelhos na retina do olho humano, introduziu o método ExR e comparou com o ExG em um experimento para segmentar regiões foliares a partir do fundo (solo). O Índice Excesso de Vermelho foi capaz de separar os *pixels* da planta dos *pixels* do fundo (solo) a equação para ExR é definido da seguinte forma:

$$ExR = 1,4 * r - g \tag{8}$$

Onde r e g são os valores digitais normalizados de R e G, de acordo com as equações 2 e 3.

2.4.1.4 ExG-ExR (Excess Green minus Excess Red Vegetation Index)

Meyer e Camargo Neto (2008) com o intuito de melhorar ainda mais a separação da vegetação dos outros elementos do fundo da imagem, subtraíram do índice ExG o índice de excesso de vermelho (ExR – *Excess Red Index*). A equação ExG (Excess Green Index) – ExR (Excess Red Index) é dada por:

$$ExG - ExR = (2 * g - r - b) - (1, 4 * r - g)$$
(9)

Onde r, g e b são os valores digitais normalizados de R, G e B, de acordo com as equações 2, 3 e 6.

De acordo com os autores, não há necessidade de determinar um limiar, ou seja, mesmo com um limiar zero já é possível satisfatoriamente separar vegetação de solo.

Estes autores explicam que existem dois problemas ainda não resolvidos quanto às pesquisas sobre índices vegetativos, que são a falta de uma definição clara do tipo de limiar (manual ou automático) a ser aplicado durante a etapa de binarização da imagem, e a falta de relatos da precisão do índice de vegetação.

Nas pesquisas revisadas nesta seção, a maioria realiza a seleção do limiar, ora manualmente através da seleção do tom de verde mais ou menos intenso (analise do histograma), ora automaticamente utilizando, por exemplo, o Método de Otsu.

2.4.1.5 MaxG (Maximum Green Index)

Fegyver (2015) propôs uma abordagem simples para separação dos *pixels* azuis de uma imagem através da identificação do azul de um *pixel*. A equação (10) exibe a proposta do autor. Fegyver afirma que um *pixel* é realmente azul, quando o componente azul é alto e os canais vermelho e verde da imagem são baixos. Assim, ele subtraiu do canal azul o máximo dos canais verde e vermelha.

$$b = B - \max(R, G) \tag{10}$$

Onde R, G e B, de acordo com as equações 2, 3 e 6, são os valores digitais de cada *pixel* das imagens coloridas nos canais vermelho, verde e azul, respectivamente.

Portanto, uma adaptação da equação (10) para subtrair o canal verde no máximo dos canalis azul e vermelha foi elaborada. A equação resultante é apresentada em (11).

$$g = G - \max(R, B) \tag{11}$$

Onde R, G e B, de acordo com as equações 2, 3 e 6, são os valores digitais de cada *pixel* das imagens coloridas nos canais vermelho, verde e azul, respectivamente.

A acurácia de índices de vegetação é um assunto pouco tratado nos estudos revisados nesta dissertação (Meyer e Camargo Neto, 2008). Gebhardt e colaboradores (2006) sugeriram que não é necessário classificar a vegetação em *pixels* com imagens digitais. No entanto, se houver muitos *pixels* de plantas misturados com *pixels* de fundo, a precisão será reduzida. Hague e seus colaboradores (2006) sugeriram uma comparação manual de áreas vegetativas a partir de fotografias de alta resolução. Até hoje, poucos estudos de índices vegetativos relataram a acurácia da detecção de material vegetal.

2.4.2 Segmentação

O processo de segmentação de imagens consiste em separar uma imagem em classes para se realizar alguma discriminação das partes (SCHALKOFF, 1989). Um exemplo de uso da segmentação no contexto de sistemas agrários é separação da vegetação em relação ao fundo, que pode ser o solo, presente nas imagens (SHRESTHA e STEWARD, 2003).

Para fazer segmentação o método mais aplicado na agricultura é a limiarização. A limiarização mais simples (*thresholding*, em inglês) consiste em separar uma imagem em região de interesse e não interesse através da escolha de um ponto de corte (JAIN et al., 1995) (MARQUES FILHO E VIEIRA NETO, 1999). Considerando a definição de um valor limiar, *pixels* que possuem valores maiores que o limiar recebem valor positivo e os *pixels* de valores menores recebem valor negativo (SOARES, 2017)..

O resultado da limiarização é tipicamente exibido em gráfico o histogramas, que representam a distribuição de *pixels* de uma imagem com relação ao tom de cor (MARQUES FILHO e VIEIRA NETO, 1999). A Figura 14 exibe três exemplos de histogramas. O eixo y representa a frequência de ocorrência da cor na imagem e o eixo x representa a intensidade da cor. T1 e T2 são limiares dos histogramas.



Figura 14 - Três exemplos de histogramas. Adaptado de Marques Filho e Vieira Neto (1999).

A Figura 15 exibe um histograma representando uma imagem em tons de cinza. A intensidade do cinza aparece no eixo x e a quantidade de *pixels* do tom de cinza aparece no eixo y. Quanto mais próximo de 0, mais escuro o tom de cinza e quanto mais próximo de 255, mais claro.



Figura 15 – Outro exemplo de histograma para a representação de limiares de tons de cinza.

A limiarização auxilia no processo de binarização da imagem, que é a separação dos objetos de interesse (destacados na cor branca) em relação ao fundo (na cor preta). Identificar o limiar ideal para esta separação pode ser difícil, por isto geralmente requer a análise de histogramas e pode levar a intervenção manual (MARQUES FILHO e VIEIRA NETO, 1999). Existem vários métodos de limiarização que automatizam a escolha do limiar de uma imagem (SHAPIRO e STOCKMAN, 2000), porém um dos métodos mais conhecidos é chamado Método de Otsu (OTSU, 1979). O Método de Otsu realiza iteração por todos os valores possíveis (faixas de tons de cinza) da imagem até encontrar o valor que minimiza a variância intraclasses.

A Figura 16 exibe um exemplo de binarização para uma muda de planta utilizando o Método de Otsu após a aplicação do índice de vegetação GRVI (explicado na Seção 2.3.2.1).



Figura 16 – Exemplo de binarização de uma imagem de planta.

2.4.3 Extração de características

Após a binarização das imagens são aplicadas algumas operações para filtragem e remoção de ruídos das imagens (MARQUES FILHO e VIEIRA NETO, 1999).

Outra operação aplicada é a de fechamento, que objetiva unir objetos próximos, eliminando também espaços isolados (SILVA JR, 2010; MARQUES FILHO e VIEIRA NETO, 1999).

A operação de abertura aplica, de forma sucessiva, operações de erosão e dilatação para eliminar pontos isolados, ou seja, estes pontos podem desaparecer ou serem divididos (SILVA JR, 2010; MARQUES FILHO e VIEIRA NETO, 1999).

As operações de erosão e dilatação são orientadas pela vizinhança, onde a vizinhança corresponde ao elemento estruturante, que varre a imagem de entrada, preservando ou invertendo o *pixel* central da vizinhança, na imagem de saída, em função dos seus vizinhos (SILVA JR, 2010; MARQUES FILHO e VIEIRA NETO, 1999).

2.4.5 Reconhecimento e Interpretação: Trabalhos Relacionados a Estimativa de Produção Agrícola

Conforme a Figura 16, esta etapa é a que atribui significado aos objetos reconhecidos após a realização das etapas anteriores de um sistema de VC. Portanto, é nesta etapa que são apresentados os trabalhos relacionados à contagem de plantas e à estimativa de produção agrícola utilizando técnicas de PDI ou VC.

Para esta revisão da literatura especificamente foi utilizada a seguinte *string* de busca no Portal de Periódicos da Capes, Google Scholar, Base de Teses e Dissertações Nacionais (BDTD) ⁴ e na Base de Teses e Dissertações Internacionais (NDLTD)⁵:

(UAV OR "Unmanned aerial vehicle")

AND

("precision agriculture" OR farming)

AND

(plant* OR seedling* OR vegetation)

AND

(productivity OR production OR estimation OR count OR quantification OR population) AND

("machine vision" OR "computer vision" OR "digital image processing" OR "remote sensing" OR "vegetation ind*")

Foram avaliados os títulos, assuntos e resumos das obras retornadas. Diversos foram os estudos envolvendo imagens de satélite e terrestres, assim como a aplicação de índices de vegetação específicos para estes tipos de imagens. Portanto, os seguintes critérios de inclusão e exclusão foram utilizados para identificar trabalhos relacionados ao tema desta pesquisa:

⁴ http://bdtd.ibict.br/

⁵ http://search.ndltd.org/

a) Critérios de inclusão:

- Estudo realizado com drone, asa voadora, planador ou balão;
- Estudo que considere imagens aéreas;
- Pesquisa que realize a contagem de plantas em lavoura;
- Pesquisa que realize a estimativa da produção agrícola;
- Pesquisa que considere índices de vegetação em camadas RGB.

b) Critérios de exclusão:

- Obra que considere imagens de satélites;
- Pesquisa que considere índices de vegetação aplicados a imagens de satélites, como NDI (Normalized Difference Index), NDVI (Normalized Difference Vegetation Index) e RVI (*Ratio Vegetation Index*);
- Trate de vegetação que esteja relacionada a elementos da paisagem e não considere plantação, lavouras ou culturas agrícolas;
- Estudo que analise ervas daninhas, solo, irrigação ao invés de plantação.

Após a aplicação dos critérios de inclusão e exclusão, poucos foram os estudos relacionados encontrados. Sete pesquisas correlacionaram a produtividade de lavouras através de índices de vegetação.

Gates e seus colaboradores (1965) explicam que a correlação entre os parâmetros biofísicos das culturas e o sensoriamento remoto, pode ser realizada por meio de índices de vegetação. Assim, os índices de vegetação são rotineiramente utilizados para aferir parâmetros das culturas, dentre estes a contagem de plantas e a consequente estimativa da produção de lavouras.

Ramme e Martello (2017) analisaram imagens RGB obtidas de um sensor de imageamento embarcado em um dispositivo móvel para extrair automaticamente a cobertura vegetal. Esta extração teve como finalidade auxiliar no desenvolvimento de uma ferramenta para a contagem da população de plantas na fase inicial do ciclo vegetativo.

Neste estudo, os autores converteram a imagem RGB para o sistema de cores formadas pelas componentes matiz (*Hue*), saturação (Saturation) e valor (Value), para então determinar por histograma o limite

inferior e superior da resposta da vegetação no canal matiz, obter a máscara a partir dos limites, e finalmente extrair o alvo (vegetação) a partir dos três canais de imagem combinados em RGB.

Os autores (RAMME e MARTELLO, 2017) também aplicaram técnicas de agrupamento de regiões e detecção de bordas com técnicas de SR para determinação de índices de vegetação GRVI (*Green Red Vegetation Index*), MGRVI (*Modified Green Red Vegetation Index*) e RGBVI (Red Green Blue Vegetation Index).

Após a determinação do índice de vegetação GRVI e MGRVI, foi aplicado um processamento de realce de visualização de contraste com corte de contagem entre os valores min/max 0,05 e 1,0. Já para o índice de vegetação RGBVI, foi aplicado um processamento de realce de visualização de contraste com corte de contagem entre os valores min/max 0,0 e 1,0.

Todas as imagens resultantes do processamento foram transformadas em imagens binárias. Na imagem de referência, em uma faixa amostral de 1180x400 *pixels*, foi delimitada manualmente a vegetação, então convertida para imagem máscara binária. A vetorização na imagem referência foi feita para observar a assertividade dos processamentos testados, permitindo realizar a comparação entre as áreas cobertas pela vegetação. Os autores concluíram que o índice de vegetação GRVI foi o que apresentou maior assertividade em relação à diferenciação da vegetação com outros alvos (RAMME e MARTELLO, 2017).

Gnädinger e Schmidhalter (2017) capturaram imagens de um VANT e as analisaram como uma técnica de fenotipagem de uma plantação de milho. Neste estudo, quatro diferentes culturas de milho foram plantadas em parcelas com diferentes sistemas de semeadura (em fileiras e equidistantemente espaçadas) e diferentes níveis de adubação nitrogenada (aplicados a 50, 150 e 250 kg N/ha). O campo experimental, abrangendo 96 parcelas, considerou a coleta de imagens a uma altura de 50 metros com um *octocopter* equipado com uma câmera de 10 megapixels tirando uma foto a cada 5 segundos. Neste estudo, as imagens foram gravadas entre BBCH 13-15 (que é uma escala para identificar o estágio de desenvolvimento fenológico de uma planta) quando a cor das folhas jovens difere das folhas mais velhas.

Correlações próximas a $R^2 = 0,89$ foram encontradas entre plantas contadas *in situ* e baseadas em imagens, adaptando um procedimento de realce por contraste, que melhorou as diferenças de cor nas imagens. Em média, o erro entre plantas visualmente e digitalmente contadas foi $\leq 5\%$. A cobertura do solo, conforme determinado pela análise de *pixels* verdes, variou entre 76% e 83% nessas fases. No entanto, a correlação entre cobertura do solo e plantas contadas digitalmente foi muito baixa. A presença de ervas daninhas e efeitos embaçados nas imagens representam possíveis erros na contagem de plantas.

Os autores concluem que a emergência final de campo do milho pode ser rapidamente avaliada e permite uma avaliação mais precisa dos parâmetros de rendimento final. Eles também comentam que o uso de VANTs e PDI têm o potencial de otimizar o gerenciamento da fazenda e apoiar a experimentação em campo para fins agronômicos e de reprodução.

No trabalho de mestrado de Leda (2016), o autor elaborou modelos matemáticos que explicam a produtividade da cana-de-açúcar por meio de técnicas de geoprocessamento e SR em uma produção agrícola nos municípios de Lençóis Paulista e Pratânia, com 6000 hectares e altimetrias variando entre 600 e 700 metros.

O autor constatou que as modelagens foram satisfatórias, variando o coeficiente de determinação entre 0,15 a 0,97. Sendo que em períodos com elevados coeficientes de determinação, podem geralmente ser encontradas áreas de forma aglomerada, o que sugere uma menor incidência de variáveis. Enquanto que em períodos com coeficientes de determinação baixos, muito provavelmente foram obtidos devido a outros fatores listados terem ocorrido, como dispersão dos talhões na área, classes de solo, precipitação e variedades da cultura.

No artigo de Nguyen e seus colaboradores (2015), os autores apresentam um sistema automatizado de VC para a enumeração de culturas

em um viveiro de mudas. O sistema completo incorpora ambos os componentes de hardware (incluindo um microcontrolador embutido, um codificador de odometria e uma câmera colorida digital não calibrada) e algoritmos de software (incluindo algoritmos de microcontroladores e o algoritmo proposto para a enumeração de árvores.

A enumeração do sistema usa um processo de análise de imagens de três etapas baseado em: (1) um método de projeção ortográfica da planta com integração de uma perspectiva transformada com estimação automática de parâmetros; (2) um método de contagem de plantas baseado em histogramas de projeção; e (3) um método de prevenção de contagem dupla baseado em transformação de homografia.

Os resultados experimentais demonstraram a capacidade de contar grandes números de plantas automaticamente sem esforço humano. Os resultados mostram que, para mudas de plantas com altura de até 40 cm e espaçamento entre árvores de aproximadamente 10 cm, os algoritmos estimaram com sucesso o número de plantas com uma precisão de 95,2% para árvores dentro de uma única imagem e 98% para contagem de toda a população de plantas em uma grande sequencia de imagens.

Brilhador e seus colaboradores (2015) propuseram um aplicativo móvel para *smartphones* e *tablets* que utiliza VC para mensuração automática dos espaçamentos entre plantas de milho em fases iniciais de crescimento. O processo realizado seguiu as etapas de aquisição de imagens panorâmicas de linhas de milho após a emergência, em condições naturais de plantio, para auxiliar a validação dos métodos utilizados como segmentação, identificação e quantificação das plantas, definição do caule e mensuração dos espaçamentos.

Os resultados obtidos pelos autores foram consideráveis, identificando 92% das plantas presentes na base com uma acurácia de 90%. Os espaçamentos entre plantas extraídos pelo método baseado em visão computacional não apresentaram diferenças significativas em comparação com as medições manuais. Chuanyu e seus colaboradores (2011) apresentaram um novo método baseado em VC também para medir o espaçamento e a população de milho na fase inicial de crescimento. As imagens foram adquiridas de uma câmera montada na parte superior sob condição de luz do dia. Algoritmos foram desenvolvidos para gerar a imagem em mosaico, segmentar a vegetação, limpar a imagem, identificar o centro de haste, encaixar linha a linha, contar as plantas e medir o espaçamento das plantas.

Comparando os resultados do sistema baseado em VC com a contagem manual em 3 variedades com 10 repetições de 10 m de seções de linhas de milho, o sistema apresentou boa correlação com a contagem manual e a estimativa do espaçamento entre plantas de milho não teve diferença com as medições manuais.

No trabalho de Leite (2011), foram avaliados os índices de vegetação NDVI, RS, GNDVI, VARI, WDRI e SAVI em imagens de duas câmeras digitais, uma sensível a região do visível (RGB) e outra sensível a região do infravermelho próximo acopladas em um balão inflado com gás hélio. Foram contabilizados o número de plantas, vagens e sementes. De acordo com os resultados obtidos não houve diferença na percentagem de emergência e no índice de velocidade de emergência nos tratamentos. Os índices de vegetação só foram capazes de diferir os tratamentos 70 dias após o plantio. Já os índices obtidos pelos valores estimados de refletância diferiram os tratamentos aos 34 e 70 dias após o plantio. Os componentes de rendimento e produtividade dos grãos não variaram em relação aos sistemas de preparo do solo.

Shrestha e Steward (2003) foram precursores no desenvolvimento de um sistema de medição da população de plantas de milho em fase inicial de crescimento com base em visão de máquina. O sistema desenvolvidos por eles considerou vídeo capturado por uma câmera digital montada em um veículo, sob diferentes condições de iluminação do dia.

Algoritmos foram desenvolvidos para sequenciar quadros de vídeo e para segmentar, isolar e contar as plantas de milho. A segmentação da vegetação foi realizada usando uma superfície de decisão elipsoidal truncada. Duas características foram extraídas de cada *pixel* das imagens segmentadas: número total de *pixels* da planta e sua posição mediana. Linhas adjacentes da mesma classe foram agrupadas e iterativamente refinadas para a contagem final das plantas.

O desempenho deste sistema foi avaliado comparando a estimativa das contagens de plantas com contagens manuais em 60 unidades experimentais de seções de 6,1 m de linhas de milho. O número de plantas de milho nessas unidades experimentais variou de 14 a 48, correspondendo a uma população de 30.000 a 103.000 plantas/ha.

Em condições de campo de baixa intensidade, a contagem de plantas do sistema foi bem correlacionada com a contagem de plantas ($R^2 = 0,90$). O erro padrão da estimativa populacional foi de 1,8 plantas pela contagem manual média de plantas de 33,2, ou 5,4% de coeficiente de variação.

Os trabalhos acima mencionados destacam existência de muitas soluções e a necessidade de utilização de sensores específicos. Portanto, ainda são esperados aprimoramentos no uso de índices de vegetação e outras técnicas de PDI e VC aplicados às imagens digitais na agricultura de precisão para melhorar as aferições nas plantações.

3. METODOLOGIA

Neste capítulo é descrita a metodologia utilizada neste estudo através da apresentação da área de estudo, dos materiais utilizados, dos procedimentos metodológicos realizados e das ameaças à validade do estudo.

3.1 Área de Estudo

A área de estudo em questão fica localizada no Estado do Pará, Município de Tucuruí. A Figura 17 mostra a localização da Região do estudo. A região em questão fica localizada próxima à linha do Equador e apresenta temperaturas mensais superiores a 24°C. O clima da região é caracterizado por ter duas estações bem definidas: um período chuvoso de Dezembro a Maio, com chuvas intensas (pluviosidade mensal de 500-600 mm/mês). Esta região apresenta um período seco entre os meses de Junho a Novembro e uma estiagem entre os meses de Agosto a Setembro, com valores pluviométricos médios de 30 mm/mês (CINTRA, 2009).



Figura 17 - Localização da Fazenda Bela Vista.

A área do estudo é denominada Fazenda Bela Vista, que possui 63 hectares de área total. Na Figura 18 é apresentada uma imagem de satélite com as coordenadas da fazenda, que são 3°39'17.0"S 49°46'32.7"W. Na Figura 19 é apresentada a área da fazenda no *Google Maps*.



Figura 18 - Imagem de satélite com as coordenadas da área selecionada 3°39'17.0"S 49°46'32.7"W. Acessada em 07 de agosto de 2018. Fonte: Google Maps.



Figura 19 – Mostra a área 63 hectares da fazenda Bela Vista.

A Figura 20 apresenta a área da plantação selecionada em azul. Esta área possui a dimensão de 1,234 ha. Já a área selecionada em vermelho foi escolhida para a aplicação dos índices, ela possui a dimensão de 327 m². Esta escolha foi feita visualmente a procura de uma área total com maior concentração possível da cultura de mandioca, visto que na agricultura familiar ocorre a mistura de outras culturas nas áreas de plantio.



Figura 20 - Área da plantação 1,234ha ou 12.234m²

A área em azul teve o melhor preparo do solo para o plantio da mandioca. O preparo do solo visa melhorar as suas características físicas, com o objetivo de favorecer o crescimento das raízes, melhora a infiltração de água e a redução da resistência do solo à expansão das raízes (EMBRAPA, 2010). Esta área o agricultor chamou de área "mecanizada".

Outro aspecto considerado foi o nivelamento da área, onde procurou-se encontrar uma área mais plana e com menos desníveis possíveis, já que é uma característica própria da região apresentar bastantes curvas de nível na plantação. Isto foi feito identificando-se os parâmetros de altitude oferecidos pela ferramenta DroneDeploy, conforme Figura 21 do modelo 3D da área. Acredita-se que este aspecto pode influenciar na irrigação do solo e consequentemente na germinação das mudas. Conforme (OTSUBO e LORENZI, 2004), o autor explica o desnível da plantação pode afetar a produção do agricultor.

Os terrenos, com topografia plana e sujeitos a encharcamentos periódicos, são também inadequados para o cultivo da mandioca, devido ao baixo desenvolvimento das plantas e o apodrecimento das raízes. É importante observar o solo em profundidade, pois a presença de uma camada argilosa ou compactada imediatamente abaixo da camada arável pode limitar o crescimento das raízes, além de prejudicar a drenagem e a aeração do solo. Com relação à topografia, os mais indicados são aqueles que apresentam terrenos planos ou levemente ondulados, com declividade de até 5%. Deve-se utilizar práticas conservacionistas do solo, pois os plantios de mandioca estão sujeitos a acentuadas perdas de solo e água por erosão (OTSUBO e LORENZI, 2004).



Figura 21 – Modelo 3D da plantação com destaque para a área segmentada (em vermelho).

3.2 Materiais utilizados

A plataforma utilizada para gerar as imagens foi selecionada pelo praticidade em operação, considerando a ficha técnica dos componentes necessários para a execução das atividades. O dispositivo a ser selecionado de acordo com os itens expostos está caracterizado na categoria dos VANTs. O VANT selecionado para os experimentos foi um DJI Phantom 4 (DJI, Shinzhen, China). Este equipamento possui pequenas dimensões cerca de 350mm na diagonal (excluindo hélices), com peso de 1388g, autonomia de cerca de 25 minutos por bateria, com velocidade máxima de 72km/h, sistema de posicionamento por satélites GPS/GLONASS, câmera de resolução de 12MP com tamanho máximo da imagem de 4000 x 3000 *pixels*. A câmera é estabilizada por um *GIMBAL tri-axial*. O controle remoto pode ser conectado a um *tablet* ou *smartphone* (DJI PHANTOM 4, 2018). A Figura 22 mostra o modelo que foi utilizado no projeto.



Figura 22 – O modelo de VANT utilizado neste estudo foi o Phantom 4 da DJI destacando (a) o controle remato, (b) a aeronave e (c) a câmera acoplada ao gimbal. Fonte: imagens retiradas do site do fabricante (DJI PHANTOM 4, 2018).

3.2.1. DroneDeploy

O software DroneDeploy é um aplicativo para planejamento de voo e aquisição de imagens. Permite a parametrização do plano de voo em função da resolução desejada para as imagens geradas: sobreposição das imagens, linhas de voo e resolução resultante. Possui um módulo de controle de voo em formato de aplicativo, compatível com o dispositivo de controle do DJI Phantom 4, no caso, um *tablet* ou celular conectado ao rádio-controle do VANT (DRONEDEPLY DOCs, 2018). A Figura 23 abaixo mostra a tela de parametrização do plano de voo.

Por se tratar de um software em nuvem, o DroneDeploy não exige que o computador do usuário tenha qualquer tipo de configuração ou prérequisitos operacionais, isto é, apenas uma conexão com internet para realizar o *upload* das imagens (DRONEDEPLY DOCs, 2018). A Figura 24 abaixo mostra a tela onde o usuário carrega as imagens para processamento. Nesta tela o usuário carrega as imagens para processamento gerando os seguintes artefatos: ortomosaicos do terreno (Mapa 2D), modelo 3D do terreno, a saúde do solo, e a elevação do terreno. Nesta tela o usuário pode realizar também a mensuração da região de estudo exibindo pontos de localização no terreno, distância entre pontos, área e volume do terreno.



Figura 23 – A tela de configuração do aplicativo DroneDeploy, de acordo com as dimensões da área a ser sensoriada. O software mostra: a duração do voo (minutos), a área (hectares), número de imagens, e quantidade de baterias gastas na execução da missão.

46



Figura 24 – A tela de upload do aplicativo DroneDeploy.

3.3. Procedimentos metodológicos

Nesta seção são explicados os passos tomados para a realização desta pesquisa, considerando as etapas da VC.

3.3.1 Domínio do problema

Conforme contextualizado na Introdução, o agricultor vende a maioria da sua produção de mandioca para um estabelecimento comercial da cidade e o restante na feira municipal. O agricultor somente quantifica a sua produção no momento da colheita.

A falta de uma estimativa antecipada afeta a negociação de preço da produção, a avaliação da saúde da plantação através da comparação das mudas em estágio inicial com as plantas no estágio final e o processo de plantio da próxima colheita, como o planejamento da compra de insumos para o preparo do solo, do processo de semeadura, etc.

Com uma contagem automática das mudas de mandioca, seria possível vender antecipadamente a produção do agricultor e preceder o

planejamento do próximo plantio, que pode até envolver outras culturas, diferentes da mandioca ao longo do tempo.

3.3.2 Aquisição de imagens

A metodologia proposta nesta pesquisa é constituída inicialmente pela coleta de imagens, utilizando o VANT em visitas programadas à fazenda. Devido à pouca disponibilidade de tempo do pesquisador e do difícil acesso à propriedade no período chuvoso, foram realizadas apenas duas visitas à fazenda para a aquisição de imagens.

As imagens foram capturadas com uma câmera RGB não métrica acoplada ao VANT explicado na Seção 3.2. Praticamente todos os voos foram realizados de forma automática, sem interferência da mão humana, apenas em caso de emergência. Com isso, as informações obtidas têm uma margem de precisão melhor, em comparação com o processo manual.

O processo para a aquisição das imagens seguiu as seguintes etapas apresentadas abaixo:

- Planejamento do plano de voo antes da chegada ao local para dimensionar de forma correta a área a ser remotamente sensoriada e a capacidade da bateria para área, pois dependendo do voo, este poderá ter a necessidade de utilizar mais de uma bateria;
- Preparação da plataforma para gerar as imagens aéreas. Esta etapa consiste (1) no carregamento da bateria do VANT e a bateria do controle remoto, (2) na checagem das hélices, (3) na verificação se o software está carregado de forma off-line no dispositivo que irá controlar a plataforma de forma automática, visto que geralmente no local não terá acesso a internet;
- Busca por um local para o experimento. Esta deveria ser uma área limpa para o pouso e sempre partir do ponto mais alto do terreno para não ter diferença de altura do terreno com a altura programada no plano de voo da aeronave, evitando assim obstáculos que poderiam causar a queda da plataforma;

 Utilização de um software capaz de realizar o recobrimento aerofotogramétrico da região e que pudesse trabalhar de forma automática. Como resultado, o software gerou o ortomosaico georreferenciado das imagens capturadas.

O processo para obter as imagens geoespaciais com VANTs parece um processo muito prático, mas requer certos cuidados como: a escolha do tipo de equipamento; a definição dos requisitos para cada tipo de processo; o conhecimento da legislação, etc. Com os cuidados necessários, os dados levantados podem apresentar qualidade suficiente para atender às demandas solicitadas.

Com a obtenção das ortofotos da área de estudo, passou-se à etapa de aplicação das técnicas de processamento das imagens com o intuito de identificar aspectos específicos da plantação, como a contagem de mudas germinadas.

3.3.3 Pré-processamento

Antes de aplicar os índices de vegetação, foram realizados dois procedimentos na etapa de pré-processamento da imagem: o redimensionamento da imagem e a separação dos canais RGB da imagem.

Foi selecionada uma imagem com dimensão 4000 x 3000 *pixels* e 81,9 MB de tamanho. Devido a limitação da ferramenta de processamento de imagens quanto à quantidade de *pixel* e tamanho da imagem, houve o redimensionamento da imagem para 55% do seu tamanho original. Com a redução, a imagem ficou com a dimensão de 1110 x 790 *pixels* e tamanho 1,2 MB.

O passo seguinte foi a separação em canais de vermelho, verde e azul (RGB). Isto é importante, pois realça as cores primárias em imagens digitais para trabalhar na escala de cinza (monocromática) de 0 a 255. As imagens resultantes foram utilizadas para a aplicação dos índices de vegetação.

3.3.4 Índices de vegetação escolhidos

Para identificar as mudas de mandioca na imagem, foram aplicados quatro índices de vegetação. Foi aplicado o índice de excesso de verde (ExG), conforme a equação (7), com a finalidade de destacar o verde da imagem. O índice de excesso de vermelho (ExR) da equação (8) também foi aplicado, pois tem sido utilizado para destacar o solo de imagens com vegetação em estágio inicial. Devido a pesquisa de Meyer e Camargo Neto (2008) ter tido bastante sucesso na separação de mudas de plantas, também consideramos aplicar a diferença entre ExG e ExR da equação (9). E por fim também consideramos a equação (11) do MaxG.

3.3.5 Segmentação

O processo de limiarização ocorreu para cada índice aplicado através da seleção automática e da seleção manual. Para cada imagem foi obtido um limiar T para o valor do *pixel* através de seu histograma.

A seleção automática utilizou o Método de Otsu e a seleção manual utilizou escolha empírica, que ocorreu após alguns testes visuais, em que o limiar se aproximou mais do tom da plantação de mandioca. Os índices que utilizaram a seleção manual seguiram a nomenclatura: ExG+ValorEmp, ExR+ValorEmp, (ExG-ExR)+ValorEmp e MaxG+ValorEmp. Já os índices que utilizaram o Método de Otsu foram nomeados: ExG+Otsu, ExR+Otsu, (ExG-ExR)+Otsu e MaxG+Otsu.

A imagem foi segmentada em duas classes, plantas e solo. *Pixels* com valor maior que o limiar T foram destacados com o valor de 255 (cor branca), estes corresponderam à classe de plantas. Os *pixels* com valor menor receberam o valor 0 (cor preta), correspondente à classe solo. Assim, foram geradas imagens binarizadas para cada índice aplicado.

3.3.6 Avaliação da acurácia dos índices

Após a binarização foi possível avaliar a acurácia dos índices de vegetação. Esta foi feita conforme o fator de qualidade definido pelo *Automatic*

Target Recognition Working Group (ATRWG) e utilizado por Meyer e Camargo Neto (2008). A equação é exibida em (12).

$$Qseg = \frac{\sum_{k,j=0}^{k,j=n,m} (A(i)_{k,j} \cap B(i)_{k,j})}{\sum_{k,j=0}^{k,j=n,m} (A(i)_{k,j} \cup B(i)_{k,j})}$$
(12)

que é o conjunto de *pixels* de plantas verdes (i = 255) ou de plano de fundo (i = 0) para cada índice aplicado. Os valores de k e j são os índices de linha e coluna para a imagem, respectivamente e, n e m são os tamanhos de linha e coluna da imagem, respectivamente.

De acordo com a equação (12), a precisão da separação da vegetação é baseada em um "e lógico" (interseção \cap) e um "ou lógico" (união \cup), comparado a uma base de *pixel* da imagem B (a imagem binarizada) para a imagem de referência A (a imagem binarizada após a segmentação de cada índice).

Na avaliação deste fator de qualidade, quanto mais próximo de 1,0 o valor de Q_{seg} , melhor é a separação de todos os *pixels* de classe selecionados. Enquanto que Q_{seg} perto de 0,0 representa uma pior separação dos *pixels* em relação a imagem B. O fator de qualidade foi aplicado a cada planta extraída da binarização automática e manual.

A Figura 25 apresenta de maneira esquemática as etapas do préprocessamento até a binarização das imagens. Primeiramente é apresentada a imagem original selecionada e capturada pelo *drone*.



Figura 25 – Fluxograma das etapas de pré-processamento, aplicação dos índices de vegetação e segmentação das imagens desta pesquisa e sua comparação ao processo manual.

A imagem binarizada gerada pelo processo manual. Foi utilizada como uma imagem de referência para ajudar na comparação dos resultados. Este processo foi feito na ferramenta gráfica Adobe Photoshop C S6 (13.0) conforme os passos a seguir:

- Aplicou-se o filtro de ajuste de contraste (valor = 35) e brilho (valor = 0);
- Depois utilizou-se a ferramenta de seleção e configurou-se a tolerância de 68. Selecionou-se o fundo (solo) e o pintou de preto;
- 3. Foram selecionadas as mudas e pintadas de branco;
- 4. Por fim, foram separadas as mudas conectadas e foram removidas as pequenas partículas.

A Figura 26 exibe a imagem resultante deste processo. Com este processo foi possível obter o total de mudas encontradas manualmente na imagem segmentada através do código apresentado no Apêndice A. O total de mudas utilizado como referência para a contagem foi de 284.



Figura 26 – Imagem binarizada do processo manual.

Em segundo lugar, foi realizado o pré-processamento com o redimensionamento das imagens e a separação dos canais no modelo RGB. Em terceiro lugar, foram aplicados os índices de vegetação ExG, ExR, (ExG-ExR), MaxG para se obter imagens em tons de cinza realçando as mudas de

mandioca. Posteriormente foram selecionados os limiares para a segmentação das imagens manualmente (Valor Empírico) e automaticamente utilizando o Método de Otsu. Para então obtermos as imagens binarizadas em que foram realizadas a contagem das mudas e a estimativa da produção para a área selecionada e área total da plantação de mandioca.

3.3.7 Extração de características

De posse das imagens binarizadas, foram aplicados filtros do MATLAB para a extração das mudas de plantas das imagens. Primeiro foi feita a limpeza de ruídos com a operação de abertura da imagem. Para remoção das partículas (*blobs*) muito pequenas, que podem ser ervas daninhas ou mudas de outras espécies de plantas. Em um segundo momento, foram preenchidas as regiões das mudas para se ter uma região uniforme.

3.3.8 Reconhecimento e Interpretação

Nesta etapa da VC é realizado o processo de contagem das plantas e a derivação da estimativa da produção, considerando sua respectiva taxa de erro para cada índice.

3.3.8.1 Contagem das plantas

Para efetuar a contagem das mudas de mandioca na área total, primeiro foi feita a contagem de mudas para a área segmentada de 327 m² e, em seguida, esta foi derivada para a área total da imagem de 12.234 m².

A contagem considerou o reconhecimento das regiões das mudas na área segmentada após a etapa de extração das características .

Após a estimativa do número de mudas na imagem selecionada, passou-se a derivação do total de mudas da área total da plantação, a qual considerou a razão da área total (12.234 m²) pela área selecionada (327 m²), que resultou em 37 vezes. Com este valor, multiplicou-se pela contagem de mudas da área selecionada para se alcançar a estimativa do total de mudas da plantação. A equação é exibida em (13).

$$QtdMudasTotal = \frac{AreaPlantacao}{AreaSelecionada} \times QtdMudasAreaSelecionada$$
(13)

3.3.8.2 Estimativa da produção

Conforme mencionado pela Embrapa (2018), cada muda de mandioca pode gerar em média até ~1,5 Kg (Região Norte 15.280kg/ha em quarto lugar na produção nacional de mandioca) de raiz mostrado na Figura 27. Levando em consideração que para cada hectare plantado temos 10.000 mudas em um espaçamento de 1,00 x 1,00m. Neste estudo, consideramos também quanto cada muda o agricultor considerou que produzia em Kg de raiz, portanto com a estimativa total de mudas da plantação, multiplicou-se pelo peso médio em Kg da raiz de mandioca produzida por cada muda para se estimar a produção. Para cada índice aplicado foram contadas as mudas de plantas para a área selecionada de 327m².



Figura 27 – Evolução da produtividade (kg/ha) de Mandioca nas Regiões do Brasil 1990 -2017.

3.3.8.3 Cálculo da taxa de contagem

A taxa de contagem é calculada pela divisão do número de mudas processadas de forma automática (processamento de imagens) e o pelo total de mudas obtidas na contagem manual. A equação é exibida em (14).

$$TaxaContagem = \left(\left(\frac{ContagemAutomatizadaMudas}{ContagemManualMudas} \right) \right) * 100\%$$
(14)

3.4 Ameaças à validade do estudo

Foram analisadas imagens de somente duas visitas à fazenda, sendo que as imagens da primeira visita foram utilizadas mais como um piloto para coleta das imagens da segunda. Portanto, não se obteve uma amostra significativa para realizar análises estatísticas e matemáticas mais aprofundadas.

A imagem selecionada para aplicação das técnicas de VC pode não ser considerada representativa para a análise da contagem de mudas, devido a uma série de características da fazenda em estudo, como o desnível do terreno, a distância entre as mudas e a distribuição das plantas (linhas do plantio).

A derivação da contagem de mudas da imagem selecionada para a área total pode não ser a mais correta, pois não foram considerados aspectos que influenciam na melhor distribuição das mudas no terreno, como a plantação de outras culturas, as linhas de plantio e o período de brotamento das mudas. A forma como foi feita derivação da estimativa da produção também pode não ser a mais adequada, pois não foram considerados fatores que afetam a produtividade da colheita, como a saúde das plantas.

A mandioca é cultivada na época chuvosa e o acesso à região fica bastante alagado, dificultando a chegada ao local. Devido à distância, à dificuldade de acesso à fazenda no período chuvoso (até mesmo com o uso de caminhonete com tração nas quatro rodas ainda ficou difícil ter acesso ao local) e a pouca disponibilidade de tempo do pesquisador (pois somente realizava as aquisições de imagens aos finais de semana), não foi possível realizar a normalização das imagens, que consiste em capturar várias imagens ao longo do dia, considerando os diferentes horários da iluminação solar, nuvens, sombras, entre outros, para se obter uma imagem normalizada refletindo estas influências. Também não foi possível coletar imagens de vários dias seguidos para realizar análises estatísticas de espaço-temporal com correlações e
regressões entre variáveis como índices de vegetação, produtividade da propriedade, períodos de coleta, solo, saúde da plantação, distância das mudas, linhas de plantio, etc. Vários fatores influenciadores não foram considerados nesta comparação, o que pode influenciar nos resultados desta pesquisa. Porém, como foi realizada uma investigação exploratória, esta pesquisa foi importante para examinar os fatores mais relevantes.

4. RESULTADOS

Neste capítulo são apresentados os resultados decorrentes das visitas à fazenda Bela Vista, onde foram realizadas as coletas de dados. A partir das imagens capturadas na fazenda, foi realizado a análise das imagens aplicando as técnicas de pré-processamento, índices de vegetação, segmentação, extração e interpretação das imagens, conforme definidas na metodologia (Capítulo 3). O resultado consiste na contagem de mudas e derivação da produção da colheita de mandioca na propriedade rural com suas taxas de contagem.

4.1 Aquisição das imagens

Antes de cada visita foi realizado o planejamento do plano de voo da aeronave, conforme exibido na Figura 28. Em seguida foi feita a preparação da plataforma para voo, conforme explicado no capítulo de Metodologia.



Figura 28 – Plano de voo da primeira visita NO DroneDeploy.

A primeira visita foi feita no dia 26 de novembro de 2017 às 11:08h da manhã para o reconhecimento da área, obtenção das respectivas coordenadas e o primeiro voo na região para captura das imagens para geração dos ortomosaicos. Nesta primeira etapa, o proprietário da fazenda mostrou a sua plantação de mandioca na fase da germinação.

Nesta visita foram tiradas 184 imagens, em uma área de 23 hectares, na altura de 100m, resolução da ortotofoto 3,0 cm/px, resolução das imagens de 12MP, dimensão das imagens de 4000 x 3000 *pixels*, com 50,8MB de espaço e utilizando uma bateria. O software DroneDeploy gerou os ortomosaicos da primeira visita, resultando na Figura 29 (a). A Figura 29 (b) corresponde ao artefato de saúde do solo, também gerado pelo software. Nesta figura pode-se observar a representação da vegetação na cor verde e do solo na cor vermelha. É possível observar que uma grande quantidade de cor vermelha, pois no momento da visita havia mais solo e menos vegetação na área da plantação. O agricultor explicou que o cultivo se encontrava em fase de germinação.





Com a experiência da visita anterior e análise preliminar das imagens, a segunda visita teve seu planejamento do plano de voo da aeronave ajustado para melhorar a qualidade e a precisão das imagens para a aplicação das técnicas de processamento de imagens. Em seguida também foi feita a preparação da plataforma para voo, conforme passos definidos na Seção 3.2.1.

Na segunda visita, realizada no dia 6 de Janeiro 2018 às 11:36h da manhã, a área já estava reconhecida e foi realizado o segundo voo na região (Figura 30). Nesta segunda etapa, a plantação de mandioca encontrava-se na fase de brotamento das mudas.



Figura 30 – Plano de voo da segunda visita no DroneDeploy.

Nesta visita foram tiradas 188 imagens, em uma área de 14 hectares, na altura de 80m, resolução de 2,4 cm/px, resolução das imagens de 12MP, dimensão das imagens de 4000 x 3000 *pixels*, com 81,9 MB de tamanho e também utilizando uma bateria. A Figura 31 mostra os ortomosaicos gerados na segunda visita e a saúde do solo. Neste momento, a quantidade de verde é superior a quantidade de vermelho.



Figura 31 – A imagem (a) representa ortomosaico retirado na segunda visita à fazenda. Comparando com a imagem (b), as áreas em vermelho misturadas com áreas em verde representam a presença de vegetação. Neste local foi realizada a plantação que se encontra em fase de brotamento das mudas.

Conforme Cardoso e seus colaboradores (2004), o tempo de brotação da mandioca é de 42 dias. Na segunda visita já haviam se passado 41 dias da primeira visita. As mudas já estavam com estatura variando entre 30cm e 40cm. Naquele momento, já foi possível considerar os ortomosaicos gerados para a realização do processamento das imagens.

Outro aspecto considerado foi o nivelamento da área, foi pesquisada uma área mais plana e com menos desníveis possíveis, já que é uma característica própria da região haver bastantes curvas de nível na plantação. Isto foi feito identificando-se os parâmetros de altitude oferecidos pela ferramenta DroneDeploy conforme Figura 32 do modelo 3D da área. Acredita se que este aspecto pode influenciar na irrigação do solo e consequentemente na germinação das mudas. Conforme (OTSUBO e LORENZI, 2004), o autor explica como o desnível acentuado da plantação pode afetar a produção do agricultor. Com relação à topografia, os mais indicados são aqueles que apresentam terrenos planos ou levemente ondulados, com declividade de até 5%.



Figura 32 – Modelo 3D da plantação com destaque para a área segmentada (em vermelho).

Na fazenda há a mistura de outras culturas na plantação de mandioca. A Figura 33 exibe múltiplas culturas, como banana e pimenta de cheiro, próximas à cultura de mandioca. Esta é uma característica própria da agricultura familiar. Portanto, é possível que a análise da área total tenha influência destas outras culturas.



Figura 33 – Culturas de banana e pimenta de cheiro próximas à cultura de mandioca da fazenda.

Assim, a escolha da imagem a ser analisada no estudo, ou seja, a segmentação da imagem dependeu dos seguintes fatores:

- 1. Uma área plana;
- 2. Uma área com a cultura de mandioca predominante, ou seja, com maior densidade da cultura;
- Uma área com o mínimo de lacunas na plantação, ou seja, com linha de plantio satisfatória;
- 4. Uma área com predominância uniforme de cores verdes, ou seja, com padronizada ocorrência de cores verdes.

A Figura 34 exibe a área selecionada que possui a dimensão de 327m². Esta área foi segmentada manualmente. É possível observar certa concentração de mudas da cultura de mandioca e igualdade no distanciamento entre elas. No entanto, percebe-se que a disposição das mudas não é muito precisa, ou seja, as linhas de plantio apresentam pouca linearidade. Isto ocorreu devido o agricultor não utilizar técnicas mais específicas para o cultivo da mandioca, conforme é orientado pela Otsubo e Lorenzi (2004).



Figura 34 – Imagem segmentada de uma área selecionada de 327m².

Todas as técnicas de VC descritas na Metodologia foram aplicadas nesta imagem selecionada manualmente. É importante destacar que a seleção de uma área o mais representativa possível possibilita a obtenção de melhores conclusões.

4.2 Pré-processamento das imagens

Conforme explicado na seção 3.3.3, a imagem selecionada foi redimensionada para sua manipulação no MATLAB. Com a redução, a imagem da Figura 33 ficou com a dimensão de 1110 x 790 *pixels* e tamanho 1,2 MB.

O passo seguinte foi a separação dos canais vermelho, verde e azul (RGB). Isto é importante, pois a separação possibilita a aplicação dos índices de vegetação escolhidos. Após a separação armazena-se as imagens resultantes nas variáveis R, G e B. As imagens resultantes são apresentadas na Figura 35 e são utilizadas para a aplicação dos índices de vegetação escolhidos.



canal R

canal G

canal B

Figura 35 – Canais RGB.

4.3 Processo de Aplicação dos Índices de Vegetação até o Tratamento das Imagens

4.3.1 ExG (Excess Green Index)

Após a aplicação da equação 6, a imagem da Figura 36 foi gerada.



Figura 36 – Imagem resultante da aplicação do ExG.

O histograma da Figura 37 foi gerado considerando a imagem resultante do cálculo do índice ExG.





Quanto mais próximo de 0 (zero), menor a luminosidade da imagem e os tons de cinza são mais escuros, portanto temos excesso de verde menos intenso. Conforme a Figura 36, estes tons indicam ser solo, resíduo ou ervas daninhas e menor possibilidade ser a plantação de mandioca.

Quanto mais próximo de 150, maior é a luminosidade da imagem e os tons de cinza são mais claros, portanto o excesso de verde é mais intenso. Conforme a Figura 37, tons mais claros indicam ser a plantação de mandioca.

Por este motivo que na análise empírica do histograma, foi selecionado um valor médio entre 0 e 150. Assim, o limiar escolhido foi de 75. O valor do índice nesta situação, que denominamos de ExG+ValorEmp, corresponde a divisão do valor escolhido pelo valor máximo do tom de cinza (255). O ExG+ValorEmp foi de 0,29.

Em seguida foi realizado o processo de binarização do ExG+ValorEmp. A imagem resultante da binarização é exibida na Figura 38.



Figura 38 – Imagem binarizada do ExG+ValorEmp.

Por fim, foram removidas as partículas muito pequenas e preenchidas as regiões das mudas. A Figura 39 exibe este processo. No Apêndice B é possível ter acesso a todo o código utilizado neste processo.



Figura 39 – Imagem após o tratamento realizado na Figura 38.

Ao considerar o limiar pelo Método de Otsu, este foi de 63. O valor do índice nesta situação, que denominamos de ExG+Otsu, corresponde a divisão deste valor pelo valor máximo do tom de cinza (255) foi de 0,25. A imagem resultante desta binarização é exibida na Figura 40 e na Figura 41 é mostrada a imagem após tratamento.



Figura 40 – Imagem binarizada do ExG+Otsu.



Figura 41 – Imagem do ExG+Otsu após tratamento.

4.3.2 ExR (Excess Red Index)

Após a aplicação da equação 8, a imagem da Figura 42 foi gerada.



Figura 42 – Imagem resultante do índice ExR.

O histograma da Figura 42 foi gerado considerando a imagem resultante do cálculo do índice ExR (Figura 43).



Figura 43 – Histograma do ExR.

Neste índice, o canal vermelho é destacado na figura, portanto a interpretação é inversa. Quanto mais próximo de 0 (zero), temos maior concentração de fundo na imagem, que no nosso caso é o objeto de interesse, ou seja, maior possibilidade de ser vegetação. E quanto mais próximo de 100, temos maior concentração de solo, resíduo ou ervas daninhas.

No histograma da Figura 43 observa-se que para valores acima de 80 encontra-se uma grande quantidade de *pixels* em tons de cinza claro. Comparando com o que é observado na Figura 42, isto significa que a imagem apresenta uma grande quantidade de solo, destacando, de maneira oposta e em escuro, a disposição das mudas na imagem. A pequena quantidade de *pixels* escuros também enfatiza o estágio em que a plantação se encontra que é de germinação.

Como foi buscado o verde da imagem, após a análise do histograma, selecionamos um valor empírico de 25, pois se aproximou mais do tom da vegetação na imagem. O ExR+ValorEmp, que é a divisão do valor escolhido pelo valor máximo do tom de cinza (255), foi de 0,10.

Em seguida foi realizado o processo de binarização, a imagem resultante da binarização é exibida na Figura 44.



Figura 44 – Imagem binarizada do ExR+ValorEmp.

Por fim, foram removidas as partículas muito pequenas e preenchidas as regiões das mudas. A Figura 44 exibe este processo. O Apêndice C apresenta o código utilizado para gerar a imagem binarizada final do ExR+ValorEmp.



Figura 45 – Imagem após a extração de características do ExR+ValorEmp.

Por outro lado, na análise com o Método de Otsu, o limiar resultante foi de 47. A divisão deste valor pelo valor máximo do tom de cinza (255) é de 0,18. A imagem resultante desta binarização é exibida na Figura 46 e na Figura 47 é mostrada a imagem após tratamento.



Figura 46 – Imagem binarizada do ExR+Otsu.



Figura 47 – Imagem do ExR+Otsu após o tratamento.

4.3.3 ExG-ExR (Excess Green minus Excess Red Vegetation Index)

Após a aplicação da equação 9, a imagem resultante é exibida na Figura 48.

Figura 48 – Imagem resultante do índice (ExG-ExR).

O histograma foi gerado considerando a imagem resultante do cálculo do índice (ExG-ExR), conforme mostrado na Figura 49. É possível perceber que a imagem não possui acentuadas curvas e vales relativos à quantidade de *pixels*, como foi visto nos histogramas dos índices ExG (Seção 4.3.1) e ExR (Seção 4.3.2). Outra análise a ser feita é a quantidade de *pixels* em tons de cinza que foi de aproximadamente 150.



Figura 49 - Histograma do (ExG-ExR).

Foi selecionado um valor médio entre 0 e 150. Assim, o limiar escolhido foi de 60. O valor do índice nesta situação, que denominamos de (ExG-ExR)+ValorEmp, corresponde a 0,24.

Em seguida foi realizado o processo de binarização do (ExG-ExR)+ValorEmp. A imagem resultante da binarização é exibida na Figura 50.

Figura 50 - Imagem binarizada do (ExG-ExR)+ValorEmp.

Por fim, foram removidas as partículas muito pequenas e preenchidas as regiões das mudas. Mostrado na Figura 51. Cujo código encontra-se no apêndice D.



Figura 51 – Imagem da Figura 50 após tratamento.

Na análise com o Método de Otsu, o limiar resultante foi de 53. A divisão deste valor pelo valor máximo do tom de cinza (255) resulta em (ExG-ExR)+Otsu igual a 0,21. A imagem resultante desta binarização é exibida na Figura 52 e na Figura 53 é mostrada a imagem após tratamento. O Apêndice E apresenta o código utilizado neste processo.



Figura 52 – Imagem binarizada do (ExG-ExR)+Otsu.



Figura 53 – Imagem binarizada do (ExG-ExR)+Otsu após tratamento.

4.3.4 MaxG (Maximum Green Index)

Após a aplicação da equação 11, a imagem resultante é exibida na Figura 54.

Figura 54 - Imagem resultante do índice MaxG.

O Histograma obtido da imagem, na Figura 55, mostra que a intensidade dos tons de cinza varia de 0 a 50, aproximadamente. Um valor próximo de 0 sugere verde menos intenso e próximo ao 50 verde mais intenso. O valor escolhido empiricamente foi de 14, pois considerou mais tons de verde escuro. Portanto, a divisão do valor escolhido pelo valor máximo do tom de cinza (255) resulta MaxG igual a 0,05.



Figura 55 - Histograma do MaxG+ValorEmp.

Semelhante ao que ocorreu com o (ExG-ExR), o histograma do MaxG também não possui curvas e vales relativos à quantidade de *pixels* e possui poucas ocorrências de cores (0 a 60, aproximadamente), como foi visto nos histogramas dos índices ExG (Seção 4.3.1) e ExR (Seção 4.3.2). A Figura 56 mostra a imagem binarizada para o MaxG+ValorEmp.



Figura 56 - Imagem binarizada do MaxG+ValorEmp.

Por fim, foram removidas as partículas muito pequenas e preenchidas as regiões das mudas mostrada na Figura 57. Cujo código encontra-se no Apêndice D.



Figura 57 – Imagem tratada do MaxG +ValorEmp.

Por outro lado, na definição automática com o Método de Otsu, o limiar resultante foi de 18. A divisão deste valor pelo valor máximo do tom de

cinza resulta MaxG+Otsu igual a 0,07. A Figura 58 apresenta a imagem binarizada do MaxG+Otsu.



Figura 58 - Imagem binarizada do MaxG+Otsu.

Por fim, foram removidas as partículas muito pequenas e preenchidas as regiões das mudas mostrada na Figura 58 e Figura 59. Cujo código encontra-se no Apêndice G.



Figura 59 – Imagem tratada do MaxG+Otsu.

A Tabela 3 apresenta os valores dos índices, seu respectivo fator de qualidade e percentual da acurácia. O fator de qualidade se aproximou de 0,7 para ExG, (ExG-ExR) e MaxG, o que se mostra satisfatório para a consideração dos tons de verde e consequente separação da vegetação. No

entanto, para o ExR o fator de qualidade foi quase 0, isto se deve a dificuldade do índice em separar vegetação, pois é mais apropriado a separar solo. Portanto, o ExR é um índice adequado na interpretação inversa deste estudo e ajuda na comparação da identificação de plantas.

Índice	Valor do índice	Fator de Qualidade	% de Acurácia
ExG+ValorEmp	0,29	0,7280	73%
ExG+Otsu	0,25	0,7332	73%
ExR+ValorEmp	0,10	0,0910	9%
ExR+Otsu	0,18	0,0143	1%
(ExG-ExR)+ValorEmp	0,24	0,6622	66%
(ExG-ExR)+Otsu	0,21	0,6960	70%
MaxG+ValorEmp	0,05	0,6984	70%
MaxG+Otsu	0,07	0,6527	65%

Tabela 3 - Valor, fator de qualidade e percentual de acurácia dos índices aplicados

4.4 Estimativa do Número de Mudas na Imagem

A Tabela 4 exibe o número de mudas obtidas em cada processo, manual ou automático com a aplicação dos índices, em conjunto com seus respectivos percentuais. As taxas de contagem foram aplicadas para cada índice, levando em consideração o valor empírico e o Otsu para a limiarização.

Tabela 4 – Quantidade de mudas, taxa de contagem e imagem binarizada por índice aplicado

Índice	Qtd. de mudas da área amostral	Taxa de contagem	Imagem
Contagem manual	284	100%	
ExG+ValorEmp	199	70%	

167	58%	
214	75%	
186	65%	
210	73%	
208	73%	
259	91%	
227	80%	
	167 214 186 210 208 259 227	167 58% 214 75% 186 65% 210 73% 208 73% 259 91% 227 80%

Em relação aos índices aplicados, o MaxG foi o que melhor fez a contagem das mudas e, por consequência, apresentou as menores taxas de contagem.

4.5 Estimativa da Produção de Mandioca da Fazenda

A Tabela 5 apresenta a estimativa da colheita em toneladas a partir da derivação da contagem de plantas, conforme explicado na Metodologia. As toneladas estimadas estão dispostas nas duas últimas colunas da tabela.

Índice	Qtd. de mudas estimadas na área amostral (327 m ²)	Qtd. de mudas estimadas na área total (12.234 M ²)	Toneladas estimadas conforme Embrapa (1,5 kg por muda)
Contagem manual	284	10508	16
ExG+ValorEmp	199	7363	11
ExG+Otsu	167	6179	9
ExR+ValorEmp	214	7918	12
ExR+Otsu	186	6882	10
(ExG-ExR) +ValorEmp	210	7770	12
(ExG-ExR)+Otsu	208	7696	12
MaxG+ValorEmp	259	9583	14
MaxG+Otsu	227	8399	12

Tabela 5 – Estimativa da colheita a partir da quantificação das mudas

4.6 Discussão dos Resultados

Na análise do histograma, percebe-se que a grande incidência de curvas acentuadas gera maior interferência na luminosidade e como consequência, maior ocorrência de cores no espectro. Essa observação acarreta na necessidade de uma seleção de limiar para melhorar a sua contagem, conforme ressaltou Soares (2017). Por outro lado, em um histograma com menor incidência de curvas acentuadas, o espectro de verde é menor, o que não acarreta na necessidade de um limiar para a interpretação da imagem.

No histograma do ExG, para valores abaixo de 25, obteve-se uma quantidade muito grande de *pixels* em tons de cinza escuro, o que significa que a imagem apresenta uma grande quantidade de solo. Isto destaca a disposição das mudas na imagem e enfatiza o estágio em que a plantação se encontra que é de germinação. Para valores medianos (ao centro), obteve-se luminosidade média e possibilidade de abranger uma quantidade maior de tons de verde que remetam às mudas. Como consequência, maior possibilidade de detectar mudas mais assertivamente do que nas extremidades.

Devido a definição do limiar para (ExG-ExR) e MaxG não ter se mostrado significativo para a interpretação das respectivas imagens resultantes, a contagem das mudas para a análise empírica e automática do histograma para o (ExG-ExR) foram próximos (210 e 208, respectivamente), assim como para o MaxG (259 e 227, respectivamente), o que sugere a possibilidade de ser desnecessário o uso de limiar nestes tipos de índice, pois a precisão pode independer da seleção do limiar.

Meyer e Camargo Neto (2008) denominam este tipo de situação de limiar zero incorporado, ou seja, não precisa de definição de limiar para a interpretação da imagem. Isto permite que um sistema de VC seja não-supervisionado na definição do limiar. Como consequência desta interpretação, a seguinte hipótese é gerada:

H1. A aplicação de índices de vegetação que independam de definição de limiar no histograma tornam a estimativa da produção de plantas mais assertiva.

O índice MaxG, que não foi muito citado na literatura, utilizando a limiarização por valor empírico, possibilitou a contagem de 91% das mudas de mandioca em relação à contagem realizada manualmente, com uma acurácia de 70%. Este índice apresentou valores resultantes da limiarização bem próximos de zero (0,05 e 0,07, respectivamente), o que significa que considerou o menor espectro de verde nas imagens. Este índice identificou mais mudas de mandioca, sendo possivelmente mais adequado para o contexto pesquisado.

O índice ExR foi o que apresentou o menor percentual de acurácia, 9% para limiar escolhido empiricamente e 1% para o limiar selecionado pelo método de Otsu. Isto era esperado, pois o ExR é apropriado para separar solo e não vegetação. No entanto, este índice apresentou o segundo melhor resultado na contagem de mudas, 75% (ExR+ValorEmp) e 65% (ExR+Otsu). O que sugere ser um índice a ser considerado para a contagem de plantas em estágios iniciais de germinação, onde o solo é predominante. O índice ExG, para ambos os métodos de limiarização, foi o que melhor separou o fundo da vegetação, pois obteve uma acurácia maior que o MaxG, que foi de 73%. No entanto, realizou a contagem mais baixa dos índices aplicados nesta pesquisa, de 70% com o método de limiarização por valor empírico e 58% com o método de Otsu. O ExG possui a característica de identificar a maior quantidade possível de tons de verde nas imagens. Isto foi possível verificar nos valores resultantes da limiarização (de 0,29 e 0,25, respectivamente), que foram os maiores entre os índices aplicados na pesquisa. Como consequência, isto afetou a contagem de mudas, pois acabou gerando muitas mudas conectadas.

Por fim, o índice (ExG-ExR) em ambos os métodos de limiarização contou 73% das mudas com acurácia de 66% para a escolha do limiar empírico e 70% para a escolha com o método de Otsu. Isto sugere ser desnecessária a definição de limiar neste caso, conforme explicado anteriormente.

Ao comparar a imagem binarizada dos índices aplicados com a do processo manual, é possível perceber que o que mais influenciou no erro da contagem foi a quantidade de mudas conectadas. Dentre os índices, o MaxG+ValorEmp foi o que obteve melhor resultado neste caso, pois foi o que conseguiu melhor separar as mudas conectadas. Por outro lado, a imagem binarizada do ExG+Otsu exibe mais mudas conectadas e, consequentemente, contou a menor quantidade de mudas.

Os outros índices tiveram taxas inferiores, o que sugere necessidade de considerar, como por exemplo, a aplicação de outras técnicas para a separação das mudas conectadas como mais um passo do processo. É importante identificar o entro de uma muda para saber quais mudas estão conectadas, conforme transformadas utilizadas na pesquisa realizada por Shrestha e Steward (2003). Portanto, mais uma hipótese é gerada:

H2. Para melhorar a assertividade da estimativa da produção agrícola, é preciso aplicar técnicas de separação de mudas conectadas após a segmentação das imagens.

A aplicação dos índices foi feita na imagem colorida original. Na etapa de pré-processamento da imagem não foram aplicados filtros para aumentar o contraste e o brilho da imagem. Uma possibilidade de melhorar a estimativa da produção é aplicar mais técnicas de pré-processamento das imagens antes da aplicação dos índices de vegetação. Portanto, uma nova hipótese pode ser gerada:

H3. A aplicação de mais técnicas de pré-processamento nas imagens pode melhorar a assertividade da estimativa da produção agrícola.

A estimativa que mais se aproximou foi a do MaxG. Ainda assim, o valor do erro variou de aproximadamente 10% a 20%. Isto pode ter ocorrido devido a uma série de fatores que influenciam na análise das imagens, como:

- 1. Os estágios das plantas;
- 2. A distância das plantas;
- 3. A saúde das plantas e do solo;
- 4. O desnível do terreno;
- 5. O processo de irrigação.

Assim, mais uma hipótese pode ser considerada:

H4. A comparação dos estágios das plantas com a sua produção podem melhorar a compreensão dos fatores que influenciam na assertividade da estimativa de um sistema de VC.

5. CONSIDERAÇÕES FINAIS

O estudo exploratório apresentado nesta pesquisa realiza a aplicação de etapas de PDI e VC em imagens capturadas por um VANT para se obter a quantificação de mudas de mandioca em uma fazenda de agricultura familiar do Município de Tucuruí e, consequentemente, a estimativa da colheita da referida cultura.

O índice MaxG apresentou o melhor resultado neste processo de contagem das mudas e estimativa da produção, contando 91% das mudas com uma acurácia de 70%. Isto significa que identificou mais mudas de mandioca, sendo possivelmente mais preciso para o contexto pesquisado.

Também foi possível concluir que o índice ExR é mais apropriado para a contagem das mudas em estágios iniciais de germinação. Já o índice (ExG-ExR) pode possibilitar a estimativa automática da produção através da criação de sistemas de VC com limiarização não supervisionada.

Por último, o índice ExG nos surpreendeu apresentando o menor desempenho para o contexto estudado. Isto é importante de ser notado, pois pode ser devido às características próprias da cultura ou da região em estudo. Pesquisas futuras mais aprofundadas precisam ser conduzidas para confirmarem estes índices.

Como contribuições práticas para o agricultor, este estudo possibilitou a conscientização da importância de prever a estimativa da colheita para melhor planejar a negociação da produção, os plantios posteriores e a busca por recursos para aumentar a área mecanizada da cultura. Também foi possível perceber a necessidade de preparar as linhas de plantio, de melhorar o preparo do solo e a irrigação, pois o agricultor somente faz o plantio no período das chuvas.

Como contribuições científicas, esta pesquisa agrega conhecimento ao destacar que, para a criação de um sistema de VC neste contexto, é importante considerar a aplicação de mais técnicas de pré-processamento nas imagens, a escolha de índices de vegetação que considerem a separação adequada do espectro de verde da cultura em questão e seus estágios de germinação, assim como a limiarização não supervisionada. E por fim, o uso de técnicas de separação de mudas conectadas após a etapa de segmentação das imagens. Estes aspectos podem tornar a estimativa da produção de plantas mais assertiva.

A assertividade da estimativa da produção agrícola também depende da consideração de fatores influenciadores, como a preparação e irrigação do solo, a distância entre as mudas e as linhas de plantio.

Outra importante contribuição desta pesquisa é a disponibilização dos códigos do projeto para a criação de uma toolbox (caixa de ferramentas computacional) em MATLAB para auxílio a futuras pesquisas de Visão Computacional aplicadas à agricultura, podendo contribuir para aumentar o uso desta tecnologia no contexto da agricultura familiar para a cultura da mandioca e outras culturas na região e no país.

5.1 Sugestões para Trabalhos Futuros

Com esta pesquisa foi possível identificar uma série de estudos em aberto. A construção de uma metodologia para monitoramento aéreo das áreas para acompanhamento do processo do plantio (semeadura, mudas, plantas, solo, irrigação, colheita, etc.) é algo que ajudaria o pequeno agricultor.

A identificação de fatores influenciadores na produtividade da colheita é um aspecto importante para ser investigado. A análise da influência do nivelamento na irrigação do solo e, consequentemente, na germinação das mudas também pode ser um trabalho futuro interessante.

A análise espaço-temporal de médio e longo prazo pode ser outro estudo apropriado para melhorar o entendimento do processo de plantio na região, como a investigação para dias ensolarados (com a maior ocorrência de cores) e para dias nublados (com a menor ocorrência de cores).

Comparação de medidas da população de plantas em estágio inicial com populações na colheita para ser usada para medir a taxa de sobrevivência das plantas durante o período de crescimento. As taxas de sobrevivência das plantas poderiam ser usadas para estimar a densidade populacional necessária no momento do plantio para atingir a densidade populacional desejada no momento da colheita. A automatização da escolha da imagem que melhor representa a lavoura pode ser um estudo de VC que eleve o nível de representatividade das imagens analisadas. Assim como a captura de mais imagens durante o processo de plantio até a colheita para a realização de correlações estatísticas e regressões lineares envolvendo os fatores influenciadores com a quantificação de plantas e sua produtividade.

A aplicação de outros índices de vegetação que pudessem melhorar a seleção do verde das plantas de acordo com a vegetação e região em estudo, como por exemplo, os tons de verde característicos da Região Amazônica.

E, por fim, a investigação de formas de otimização da irrigação do solo com a geração das curvas de nível para que o proprietário rural consiga tomar decisão sobre como fazer os canais de irrigação.

.

REFERÊNCIAS BIBLIOGRÁFICAS

AUVSI (Association for Unmanned Vehicle Systems International) (2013) The Economic Impact of Unmanned Aircraft Systems Integration in the United States. Economic Report, disponível online em: http://www.auvsi.org/our-impact/economic-report acessado em: 05/01/2018.

BATISTA, L. V. Introdução ao Processamento Digital de Imagens. lucianowjr. googlepages. com/PDI2006. ppt, acessado em, 8, 2005.

BANNARI, A., MORIN, D., BONN, F., HUETE, A. R. A Review of Vegetation Indices. Remote Sensing Reviews, vol. 13, pags. 95-120, 1995.

BENDIG, J., YU, K. AASEN, H., BOLTEN, A., BENNERTZ, S., BROSCHEIT, J. MARTIN L. Gnypa,b,c, Georg Baretha, cCombining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. International Journal of Applied Earth Observation and Geoinformation, vol. 39, pags. 79–87. Elsevier, 2015.

CHAMARD, P., COUREL, M. F., DUCOUSSO, M., GUÉNÉGOU, M. C., LE RHUN, J., LEVASSEUR, J. E., LOISEL, C. AND TOGOLA, M. Utilisation des bandes spectrales du vert et du rouge pour une meilleure évaluation des formations végétales actives. **Télédétection et Cartographie**, Éd. AUPELF-UREF, 203-209, 1991.

CAMMARANO, D., FITZGERALD, G. J., CASA, R., BASSO, B. Assessing the Robustness of Vegetation Indices to Estimate Wheat N in Mediterranean Environments. Remote Sens. 2014, 6(4), 2827-2844. https://doi.org/10.3390/rs6042827'

CARVALHO, I. F. Agricultura de precisão: boletim técnico. Brasília: Mapa/ACS, 2011.

CHIACCHIO, S. S. R. Veículo aéreo não tripulado de asa rotativa na atividade de mapeamento e coleta de imagem na agricultura de precisão e no monitoramento de animais. Tese de Doutorado. Universidade de São Paulo, 2017.

CASTLEMAN, K.R., Digital Image Processing, Prentice-Hall, 1995.

CINTRA, I. H. A., JURAS, A. A., SILVA, K. C. A., TENÓRIO, G. S., & OGAWA, M. Apetrechos de pesca utilizados no reservatório da usina hidrelétrica de Tucuruí (Pará, Brasil). **Boletim Técnico-Científico do CEPNOR**, v. 9, n. 1, p. 67-79, 2009.

DE QUEIROZ, José Eustáquio Rangel; GOMES, Herman Martins. Introdução ao processamento digital de imagens. RITA, v. 13, n. 2, p. 11-42, 2006.

DE SOUZA, C. H. W., LAMPARELLI, R. A. C., ROCHA, J. V., & MAGALHÃES, P. S. G. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture**, v. 143, p. 49-56, 2017.

DIKER, K.; BAUSCH, W.C.; PODMORE, T.H. GIS Mapping of Plant Parameters and Yield Potential Estimated by Remote Sensing. ASAE Meeting, Orlando/ Flórida, n. 983143, 1998.

DJI PHANTOM 4

<https://store.dji.com/shop/phantom-series?from=menu_products/> acesso em: 01 fev. 2018.

DRONEDEPLY

https://www.dronedeploy.com> acesso em: 05 jan. 2018.

DRONEDEPLY DOCs

https://support.dronedeploy.com/docs acesso em: 04 fev. 2018.

EMBRAPA

< https://www.embrapa.br/congresso-de-mandioca-2018/mandioca-emnumeros> acesso em: 28 jun. 2018, 2018.

EMBRAPA

<http://www.cpatsa.embrapa.br:8080/sistema_producao/spuva/mecanizacao.ht ml> acesso em: 28 jun. 2018, 2010.

FELIX, F. C., AVALOS, F. A. P., SILVA, M. L. N., & MINCATO, R. L. Mapeamento da cobertura vegetal a partir de imagens de alta resolução

obtidas por VANT. Os Desafios da Geografia Física na Fronteira do Conhecimento, v. 1, n. 2017, p. 5095-5105, 2017.

FEGYVER, Z. A simple image segmentation example in MATLAB. Matlab Tricks.com, 2015. Disponível em: <u>http://matlabtricks.com/post-35/a-simple-image-segmentation-example-in-matlab</u>. Acessado em 03/04/2018.

FERNANDES, J. L.; ROCHA, J. V.; LAMPARELLI, R. A. C. Sugarcane yield estimates using time series analysis of spot vegetation images. Sci. agric., Piracicaba, v. 68, n. 2, p. 139-146, 2011.

GNADINGER, F. E SCHMIDHALTER, U. Digital Counts of Maize Plants by Unmanned Aerial Vehicles (UAVs). Remote Sensing 2017, 9(6), 544; doi:10.3390/rs9060544, 2017.

GONZALEZ, R.C. E WOODS, R.E., Digital Image Processing, Addison-Wesley, 1992.

GONZALEZ-DUGO, V., ZARCO-TEJADA, P., NICOLÁS, E., NORTES, P. A., ALARCÓN, J. J., INTRIGLIOLO, D. S., & FERERES, E.Using high resolution UAV thermal imagery to assess the variability in the water status of five fruit tree species within a commercial orchard. **Precision Agriculture**, v. 14, n. 6, p. 660-678, 2013.

HUNT, E., DAUGHTRY, C., MIRSKY, S., HIVELY, W. Remote sensing with simulated unmanned aircraft imagery for precision agriculture applications. **IEEE J. Sel. Top. Appl**. Earth Observ. Remote Sens., 2014.

JAIN, R.C., KASTURI, R., E SCHUNCK, B.G., Machine Vision, McGraw-Hill, 1995.

LU, B., HE, Y., & LIU, H. H. Mapping vegetation biophysical and biochemical properties using unmanned aerial vehicles-acquired imagery. **International Journal of Remote Sensing**, p. 1-23, 2017.

LI, Z., LIU, Y., WALKER, R., HAYWARD, R., & ZHANG, J.Towards automatic power line detection for a UAV surveillance system using pulse coupled neural

filter and an improved Hough transform. **Machine Vision and Applications**, v. 21, n. 5, p. 677-686, 2010.

LONGHITANO, G. A. VANTS para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas. Tese de Doutorado. Universidade de São Paulo, 2010.

LINHARES, M. M. D. A. Uso de veículo aéreo não tripulado na determinação de Índice de vegetação em área de pastagem em Nova Mutum-MT, 2016.

LUCIEER, A., TURNER, D., KING, D.H., ROBINSON, S.A. Using an Unmanned Aerial Vehicle (UAV) to capture micro-topography of Antarctic moss beds. Int. J. Appl. Earth Observ. Geoinform. 27, 53–62, 2014.

MCNAIRN, H. E PROTZ, R. Mapping corn residue cover on agricultural fields in Oxford County, Ontario, using Thematic Mapper. **Canadian Journal of Remote Sensing** 19 (2): 152-159, 1993.

MANTOVANI, E. C., QUEIROZ, D. M., & DIAS, G. P. Máquinas e operações utilizadas na agricultura de precisão. In: **Embrapa Milho e Sorgo-Artigo em anais de congresso (ALICE)**. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRICOLA, 27., 1998, Poços de Caldas, MG. Mecanização e agricultura de precisão. Lavras: UFLA/SBEA, 1998. p. 109-157., 1998.

MAO, W., WANG, Y., & WANG, Y. Real-time detection of between-row weeds using machine vision. In: **2003 ASAE Annual Meeting**. American Society of Agricultural and Biological Engineers, p. 1, 2003.

MARQUES FILHO, O.; VIEIRA NETO, H. Processamento Digital de Imagens, Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

MENDONÇA, J. C., FREITAS, R. M. D., AGUIAR, D. A. D., SOUSA, E. F. D., MUNIZ, R. D. A., & ESTEVES, B. D. S. Mapeamento das áreas de cana-deaçúcar na região norte fluminense-RJ por uso de técnicas de sensoriamento remoto Mapping of sugarcane areas in the north fluminense region, RJ using remote sensing techniques. **Engenharia Agrícola**, v. 31, n. 3, p. 561-571, 2011. MEDEIROS, F. A. Desenvolvimento de um veículo aéreo não tripulado para aplicação em agricultura de precisão, 2007.

MONTALVO, M., PAJARES, G., GUERRERO, J. M., ROMEO, J., GUIJARRO, M., RIBEIRO, A., ... & CRUZ, J. M. Automatic detection of crop rows in maize fields with high weeds pressure. **Expert Systems with Applications**, v. 39, n. 15, p. 11889-11897, 2012.

MEYER, G. E., CAMARGO NETO, J. Verification of color vegetation indices for automated crop imaging applications. computers and electronics in agriculture, vol. 63, pags. 282–293. Elsevier, 2008.

MEYER, G. E., HINDMAN, T. W., & LAKSMI, K. Machine vision detection parameters for plant species identification. In *Precision Agriculture and Biological Quality*(Vol. 3543, pp. 327-336). International Society for Optics and Photonics, 1999.

MONTEIRO, P. F. C.; et al . Índices de vegetação simulados de diferentes sensores na estimativa das variáveis biofísicas do feijoeiro. Pesq. agropec. bras., Brasília , v. 48, n. 4, p. 433-441, 2013 . Disponivel em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2013000400012&Ing=en&nrm=iso. Acesso em: 05 Abr. 2018.

MOTOHKA, T., NASAHARA, K. N., OGUMA, H., TSUCHIDA, S. Applicability of green–red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, vol. 2, pags. 2369–2387, 2010.

MOUTINHO, O. F. G. Evaluation of Photogrammetric Solutions for RPAS: Commercial vs Open Source, 2015.

MUNARETTO, L. A. C. Vant e Drones – A aeronáutica ao alcance de todos. **São José dos Campos**, 2015.

INAMASU, R. Y.; BERNARDI, A. C. de C.; NAIME, J. de M.; QUEIROS, L. R.; RESENDE, A. V. de; VILELA, M. de F.; BASSOI, L. H.; PEREZ, N. B.; FRAGALLE, E. P. Estratégia de implantação, gestão e funcionamento da Rede Agricultura de Precisão. **Agricultura de precisão: um novo olhar**. São Carlos, SP: Embrapa Instrumentação, p. 31-40, 2011. JORGE, L. D. C.; INAMASU, R. Y.; DO CARMO, R. B. Desenvolvimento de um VANT totalmente configurado para aplicação em Agricultura de Precisão no Brasil. In: **Embrapa Instrumentação-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO-SBSR, 15., 2011, Curitiba. Anais... São José dos Campos: INPE, 2011. p. 399-406., 2011.

JORGE, L. D. C., & INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. Embrapa Instrumentação-Capítulo em livro técnico-científico (ALICE), 2014.

JORGE, L. D. C., & TRINDADE JR, O. Metodologia para utilização de aeromodelos em monitoramento aéreo. Embrapa Instrumentação Agropecuária-Circular Técnica (INFOTECA-E), 2002.

PEREZ, A.J., LOPEZ, F., BENLLOCH, J.V., CHRISTENSEN, S. Color and shape analysis techniques for weed detection in cereal fields. **Computer and Electronics in Agriculture** 25, 197–212, Elsevier, 2000.

PICOLI, M.C.A.; RUDORFF, B.F.T.; RIZZI, R.; GIAROLLA, A. Índice de vegetação do sensor MODIS na estimativa da produtividade agrícola da canade-açúcar. Revista Bragantia, Campinas, v. 68, n. 3, p. 789-795, 2009.

QUEIROZ, Corina Jará de. Análise de Transformações Geométricas para o Georreferenciamento de Imagens do Satélite CBERS-I. **Dissertação de Mestrado**. UFRGS - CEPSRM, 2003. Disponível em www.ufrgs.br/srm/DissertaçõesPos/A18.html. Acessada em 10 de Abril de 2018.

REDWEIK, P. Fotogrametria aérea. Faculdade de Ciências da Universidade de Lisboa, Lisboa. Pág, 3, 2007.

RIZZI, R.; RUDORFF, B.F.T. Imagens do sensor MODIS associadas a um modelo para estimar a produtividade de soja. Pesquisa Agropecuária Brasileira, Brasília, 42, p.73-80, 2007.

SCHALKOFF, R.J., Digital Image Processing and Computer Vision. Wiley, 1989.

SENOP

< http://senop.fi/optronics-hyperspectral#hyperspectralCamera> acesso em: 05 jan. 2018

SHAPIRO, L. E STOCKMAN, G. Computer Vision. Pearson, 2000.

SHRESTHA, D. S., & STEWARD, B. L. Automatic corn plant population measurement using machine vision. Transactions of the ASAE, 46(2), 559, 2003.

SIEBERT, S., TEIZER, J. Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system. **Automation in Construction**, v. 41, p. 1-14, 2014.

SIMÕES, M. S.; ROCHA, J. V.; LAMPARELLI, R. A. C. Growth indices ans productivity in sugarcane. Sci. agric. (Piracicaba, Braz.), Piracicaba, v. 62, n.1, p. 23-30, Jan. 2005.

SOARES, G. A. Identificação de linhas de plantio por meio da transformada de Hough, 2017.

SONNENTAG, O., HUFKENS, K., TESHERA-STERNE, C., YOUNG, A. M., FRIEDL, M., BRASWELL, B. H., ... & RICHARDSON, A. D. Digital repeat photography for phenological research in forest ecosystems. **Agricultural and Forest Meteorology**, v. 152, p. 159-177, 2012.

SOUSA, J. M. C. D. Avaliação do potencial da utilização de veículos aéreos não tripulados na investigação de acidentes de viação, 2017.

SOUSA, B. D. C. Modelo digital de elevação a partir de imagens de Vant aplicado na identificação de áreas suscetíveis a alagamentos e, uma sub-bacia hidrográfica da cidade de Teresina–Piauí, 2017.

SILVA, J. F. D. Uma solução de baixo custo para o processamento de imagens aéreas obtidas por Veículos Aéreos Não Tripulados, 2016.

TEMBA, P. Fundamentos da fotogrametria. Belo Horizonte: UFMG, 2000
TETRACAM

< http://www.tetracam.com/Products1.htm > acesso em: 01 fev. 2018.

TIAN, J., WANG, L., LI, X., GONG, H., SHI, C., ZHONG, R., & LIU, X. Comparison of UAV and WorldView-2 imagery for mapping leaf area index of mangrove forest. International Journal of Applied Earth Observation and Geoinformation, v. 61, p. 22-31, 2017.

TUCKER, C.J.RED and photographic infrared linear combinations for monitoring vegetation. Remote Sens. Environ. 8, 127–150, 1979.

VELODYNE LIDAR

http://velodynelidar.com/management.html> acesso em: 05 jan. 2018.

VERHOEVEN, G., 2011. Taking computer vision aloft – archaeological threedimensional reconstructions from aerial photographs with photoscan. **Archaeol. Prospect**. 18, 67–73, 2011.

WANG, Y., WANG, D., ZHANG, G., & WANG, J. Estimating nitrogen status of rice using the image segmentation of GR thresholding method. **Field Crops Research**, v. 149, p. 33-39, 2013.

WOEBBECKE, D. M., MEYER, G. E., VON BARGEN, K., & MORTENSEN, D. A. Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259-269, 1995.

KAWASHIMA, S., & NAKATANI, M. An algorithm for estimating chlorophyll content in leaves using a video camera. **Annals of Botany**, v. 81, n. 1, p. 49-54, 1998.

OTSU, N. A threshold selection method from gray-level histogram. IEEE Transactions on Systems Man and Cybernetics, v. 9, n. 1, p. 62-66, 1979.

OTSUBO, A. A., LORENZI, J. O. Cultivo da mandioca na região Centro-Sul do Brasil. Embrapa Agropecuária Oeste-Sistema de Produção (INFOTECA-E), 2004.

WORKSWELL S.R.O

https://www.drone-thermal-camera.com/wiris/ acesso em: 01 fev. 2018.

APÊNDICES

APÊNDICE A

Contagem manual de mudas

```
% ler imagem Area de 327m2
Im = imread('plantacao2_contagem_manual.png');
ImRedimencionar = imresize(Im, 0.55); % redimencionar imagem
Igray = rgb2gray(ImRedimencionar);
imshow(Igray);
imBW = imbinarize(Igray); % Binarização da imagem
imshow(imBW);
s = regionprops(imBW, 'Centroid');
%imshow(bw2)
hold on
for k = 1:numel(s)
    c = s(k).Centroid;
    text(c(1), c(2), sprintf('%d', k), ...
        'HorizontalAlignment', 'center', ...
'VerticalAlignment', 'middle', 'Color', 'red', 'FontSize', 10, 'FontWeight',
'bold');
end
hold off
```

APÊNDICE B

```
ExG
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
%_____
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando o Índice de Excesso de Verde (ExG).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                               % Canal Vermelho
G = ImRedimensionar(:,:,2);
                               % Canal Verde
B = ImRedimencionar(:,:,3);
                               % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
%_____
% Cálculo do ExG
ExG = 2*G-R-B;
%imshow(ExG);
٥،
% Histograma a mostra relação do número de pixel pela intensidade de
cinza
% o histograma foi gerado considerando a imagem resultante do calculo
índice
% de excesso de verde (ExG).
%imhist(ExG);
٥,_____
% Após a analise do histograma foi selecionado um a valor de forma
empírico
% entre 0-150 este valor foi de 75
ValorEmpirico = 75.0/255.0;
%_____
% Em seguida foi realizado o processo de binarização da imagem em
escala
% de cinza utilizando com limiar(threshold) o valor de 75 (determinado
% empiricamente) e o imagem resultante do calculo índice excesso de
verde
% (ExG).
imBinarizada = imbinarize(ExG, ValorEmpirico);
```

```
⁰_____
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras espécies de plantas.
imParticulasRemovidas = bwareaopen(imBinarizada, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroIExG = ((NumeroMudas/284) - 1) * 100;
%imshow(ExG);
%imshow(imBinarizada);
%-----VISUALIZCÃO DOS RESULTADOS------
subplot(2,3,1); imhist(ExG); title(['Hist. ',num2str(ValorEmpirico),'
(Valor empirico)']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada
(IExG) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroIExG) ,' %' ]);
```

APÊNDICE C

ExR clear; Im = imread('plantacao2.png'); %-----PRÉ-PROCESSAMENTO------ImRedimencionar = imresize(Im, 0.55); whos %_____ % Modelo RGB; % O nome deste modelo e a abreviação RGB vêm das três cores primárias % aditivas: vermelho, verde e azul (Red, Green e Blue) espectro cromático. % Iremos transformar a imagem RGB em uma % imagem em escala de cinza usando o Índice de Excesso de Verde (ExR). %Separando os canais de cores (R,G,B) R = ImRedimencionar(:,:,1); % Canal Vermelho G = ImRedimensionar(:,:,2);% Canal Verde B = ImRedimencionar(:,:,3); % Canal Azul %figure; imshow(R);title('Canal Vermelho'); %figure; imshow(G);title('Canal Verde'); %figure; imshow(B);title('Canal Azul'); 9._____ % Cálculo do ExR ExR = 1.4 * R - G;%_____ % Histograma a mostra relação do número de pixel pela intensidade de cinza % o histograma foi gerado considerando a imagem resultante do calculo índice % de excesso de vermelho (ExR). %imhist(ExR); % % Após a analise do histograma foi selecionado um a valor de forma empírico % entre 0-100 este valor foi de 25 ValorEmpirico = 25.0/255.0; ۶_____ % Em seguida foi realizado o processo de binarização da imagem em escala % de cinza utilizando com limiar(threshold) o valor de 25 (determinado % empiricamente) e o imagem resultante do calculo índice excesso de % vermelho % (ExR). imBinarizada = imbinarize(ExR,ValorEmpirico);

```
%Inverte as cores da imagem binarizada
imInverter = imcomplement(imBinarizada);
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras especies de plantas.
imParticulasRemovidas = bwareaopen(imInverter, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
%-----PROCESSAMENTO------
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroIExR = ((NumeroMudas/284) - 1) * 100;
%imshow(ExR);
%imshow(imInverter);
8-----VISUALIZÇÃO DOS RESULTADOS------VISUALIZÇÃO DOS RESULTADOS-----
subplot(2,3,1); imhist(ExR); title(['Hist. ',num2str(ValorEmpirico),'
(Valor empirico)']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada
(ExR) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroIExR) ,' %' ]);
```

APÊNDICE D

```
ExG-ExR
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
°c-----
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando a diferença de índices(ExG - ExR).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                               % Canal Vermelho
G = ImRedimensionar(:,:,2);
                               % Canal Verde
B = ImRedimencionar(:,:,3);
                               % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
9<u>.</u>_____
% Cálculo da diferença de índices(ExG - ExR)
ExG = 2*G-R-B;
ExR = 1.4 * R - G;
GxR = ExG - ExR;
%imshow(GxR);
9._____
% Histograma a mostra relação do número de pixel pela intensidade de
cinza
% o histograma foi gerado considerando a imagem resultante do calculo
% diferença de índices(ExG - ExR).
%imhist(GxR);
oʻo_____
% Após a analise do histograma foi selecionado um a valor de forma
empírico
% entre 0-150 este valor foi de 60
ValorEmpirico = 60.0/255.0;
% Em seguida foi realizado o processo de binarização da imagem em
escala
% de cinza utilizando com limiar(threshold) o valor de 75 (determinado
```

```
% empiricamente) e o imagem resultante do calculo da diferença de
índices
% (ExG - ExR)
imBinarizada = imbinarize(GxR,ValorEmpirico);
0,
                                        _____
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras especies de plantas.
imParticulasRemovidas = bwareaopen(imBinarizada, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
%-----PROCESSAMENTO------
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroGxR = ((NumeroMudas/284) - 1) * 100;
%imshow(GxR);
%imshow(imBinarizada);
%-----VISUALIZÇÃO DOS RESULTADOS-----
subplot(2,3,1); imhist(GxR); title(['Hist. ',num2str(ValorEmpirico),'
(Valor empirico)']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada (ExG -
ExR) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroGxR) ,' %' ]);
```

APÊNDICE E

```
MaxG
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
%_____
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando o Índice de Máximo de Verde (MaxG).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                               % Canal Vermelho
G = ImRedimensionar(:,:,2);
                               % Canal Verde
B = ImRedimencionar(:,:,3);
                               % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
۶<u>_____</u>
____
% Cálculo do ExG
MaxG = G - max(R,B);
%imshow(MaxG);
%
% Histograma a mostra relação do número de pixel pela intensidade de
cinza
% o histograma foi gerado considerando a imagem resultante do calculo
índice
% de máximo de verde (MaxG).
%imhist(MaxG);
%_____
% Após a analise do histograma foi selecionado um a valor de forma
empírico
% entre 0-50 este valor foi de 24
ValorEmpirico = 14.0/255.0;
____
% Em seguida foi realizado o processo de binarização da imagem em
escala
% de cinza utilizando com limiar(threshold) o valor de 24 (determinado
% empiricamente) e o imagem resultante do calculo índice máximo de
verde
```

```
% (MaxG).
imBinarizada = imbinarize(MaxG,ValorEmpirico);
8-----
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras especies de plantas.
imParticulasRemovidas = bwareaopen(imBinarizada, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroMaxG = ((NumeroMudas/284) - 1) * 100;
%imshow(MaxG);
%imshow(imBinarizada);
%-----VISUALIZÇÃO DOS RESULTADOS-----
subplot(2,3,1); imhist(MaxG); title(['Hist. ',num2str(ValorEmpirico),'
(Valor empirico)']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada
(MaxG) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroMaxG) , ' %' ]);
```

APÊNDICE F

```
ExG+Otsu
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
%_____
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando o Índice de Excesso de Verde (ExG).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                               % Canal Vermelho
G = ImRedimensionar(:,:,2);
                               % Canal Verde
B = ImRedimencionar(:,:,3);
                               % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
۶<u>_____</u>
% Cálculo do ExG
ExG = 2*G-R-B;
%_____
% Histograma a mostra relação do número de pixel pela intensidade de
cinza
% o histograma foi gerado considerando a imagem resultante do calculo
índice
% de excesso de verde (ExG).
%
% No histograma foi utilizado método de Otsu para determinar o valor
% ideal de um threshold que separe os elementos do fundo e da frente
da
% imagem em dois clusters, atribuindo a cor branca ou preta para cada
um
% deles.
[counts,x] = imhist(ExG);
stem(x, counts);
T = otsuthresh(counts);
<u>8</u>_____
% Em seguida foi realizado o processo de binarização da imagem em
escala
```

```
% de cinza utilizando com limiar(threshold) o valor T de Otsu e o
imagem
% resultante do calculo índice excesso de verde (ExG).
imBinarizada = imbinarize(ExG,T);
∞
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras espécies de plantas.
imParticulasRemovidas = bwareaopen(imBinarizada, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
%-----PROCESSAMENTO------
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroIExG = ((NumeroMudas/284) - 1) * 100;
%imshow(ExG);
%imshow(imBinarizada);
%-----VISUALIZÇÃO DOS RESULTADOS-----
subplot(2,3,1); imhist(ExG); title(['Hist. ',num2str(T),' (Valor de
Otsu) ']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada
(IExG) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroIExG) ,' %' ]);
```

APÊNDICE H

ExR+Otsu

```
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
%_____
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando o Índice de Excesso de Verde (ExG).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                               % Canal Vermelho
G = ImRedimensionar(:,:,2);
                               % Canal Verde
B = ImRedimencionar(:,:,3);
                               % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
۶<u>_____</u>
% Cálculo do ExR
ExR = 1.4 * R - G;
%_____
% Histograma a mostra relação do número de pixel pela intensidade de
cinza
% o histograma foi gerado considerando a imagem resultante do calculo
índice
% de excesso de verde (ExG).
%
% No histograma foi utilizado método de Otsu para determinar o valor
% ideal de um threshold que separe os elementos do fundo e da frente
da
% imagem em dois clusters, atribuindo a cor branca ou preta para cada
um
% deles.
[counts,x] = imhist(ExR);
stem(x, counts);
T = otsuthresh(counts);
<u>8</u>_____
% Em seguida foi realizado o processo de binarização da imagem em
escala
```

```
% de cinza utilizando com limiar(threshold) o valor T de Otsu e o
imagem
% resultante do calculo índice excesso de verde (ExG).
imBinarizada = imbinarize(ExR,T);
∞
%Inverte as cores da imagem binarizada
imInverter = imcomplement(imBinarizada);
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras espécies de plantas.
imParticulasRemovidas = bwareaopen(imInverter, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
%-----PROCESSAMENTO------
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroIExR = ((NumeroMudas/284) - 1) * 100;
%imshow(ExG);
%imshow(imInverter);
%-----VISUALIZÇÃO DOS RESULTADOS------
subplot(2,3,1); imhist(ExR); title(['Hist. ',num2str(T),' (Valor de
Otsu) ']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada
(IExR) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroIExR) ,' %' ]);
```

APÊNDICE I

```
(ExG-ExR)+Otsu
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
%_____
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando a diferença de índices(ExG - ExR).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                                % Canal Vermelho
G = ImRedimencionar(:,:,2);
                                % Canal Verde
B = ImRedimencionar(:,:,3);
                                % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
9<u>.</u>_____
% Cálculo da diferença de índices(ExG - ExR)
ExG = 2*G-R-B;
ExR = 1.4 * R - G;
GxR = ExG - ExR;
%imshow(GxR);
<u>ي</u>
% No histograma foi utilizado método de Otsu para determinar o valor
% ideal de um threshold que separe os elementos do fundo e da frente
da
% imagem em dois clusters, atribuindo a cor branca ou preta para cada
um
% deles.
[counts,x] = imhist(GxR);
stem(x, counts);
T = otsuthresh(counts);
%_____
% Em seguida foi realizado o processo de binarização da imagem em
escala
% de cinza utilizando com limiar(threshold) o valor T de Otsu e o
imagem
```

```
% resultante do calculo da diferença de índices (ExG - ExR)
imBinarizada = imbinarize(GxR,T);
∞
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras espécies de plantas.
imParticulasRemovidas = bwareaopen(imBinarizada, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
%-----PROCESSAMENTO------
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroGxR = ((NumeroMudas/284)-1)*100;
%imshow(GxR);
%imshow(imBinarizada);
%-----VISUALIZÇÃO DOS RESULTADOS-----
subplot(2,3,1); imhist(GxR); title(['Hist. ',num2str(T),' (Valor de
Otsu) ']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada (ExG -
ExR) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroGxR) ,' %' ]);
```

APÊNDICE J

MaxG+Otsu

```
clear;
Im = imread('plantacao2.png');
ImRedimencionar = imresize(Im, 0.55);
whos
%_____
% Modelo RGB;
% O nome deste modelo e a abreviação RGB vêm das três cores primárias
% aditivas: vermelho, verde e azul (Red, Green e Blue) espectro
cromático.
% Iremos transformar a imagem RGB em uma
% imagem em escala de cinza usando o índice de máximo de verde (MaxG).
%Separando os canais de cores (R,G,B)
R = ImRedimencionar(:,:,1);
                               % Canal Vermelho
G = ImRedimensionar(:,:,2);
                               % Canal Verde
B = ImRedimencionar(:,:,3);
                               % Canal Azul
%figure; imshow(R);title('Canal Vermelho');
%figure; imshow(G);title('Canal Verde');
%figure; imshow(B);title('Canal Azul');
۶<u>_____</u>
% Cálculo do MaxG
MaxG = G - max(R,B);
%_____
% Histograma a mostra relação do número de pixel pela intensidade de
cinza
% o histograma foi gerado considerando a imagem resultande do calculo
índice
% de maximo de verde (MaxG).
%
% No histograma foi utilizado método de Otsu para determinar o valor
% ideal de um threshold que separe os elementos do fundo e da frente
da
% imagem em dois clusters, atribuindo a cor branca ou preta para cada
um
% deles.
[counts,x] = imhist(MaxG);
stem(x, counts);
T = otsuthresh(counts);
۶_____
% Em seguida foi realizado o processo de binarização da imagem em
escala
```

```
% de cinza utilizando com limiar(threshold) o valor T de Otsu e o
imagem
% resultante do calculo índice máximo de verde (MaxG).
imBinarizada = imbinarize(MaxG,T);
∞
% Remove os blobs(partículas) muito pequenas podendo ser ervas
daninhas
% ou mudas de outras espécies de plantas.
imParticulasRemovidas = bwareaopen(imBinarizada, 50);
%4-Preencher regiões das mudas
imMudasPreenchidas = imfill(imParticulasRemovidas, 'holes');
%-----PROCESSAMENTO------
% Contagem do número de mudas.
Contagem = bwconncomp(imMudasPreenchidas);
NumeroMudas = Contagem.NumObjects;
% Analise do erro.
ErroMaxG = ((NumeroMudas/284) - 1) * 100;
%imshow(GxR);
%imshow(imBinarizada);
%-----VISUALIZÇÃO DOS RESULTADOS-----
subplot(2,3,1); imhist(MaxG); title(['Hist. ',num2str(T),' (Valor de
Otsu) ']);
subplot(2,3,2); imshow(imBinarizada); title('Imagem binarizada
(MaxG) ');
subplot(2,3,3); imshow(imParticulasRemovidas); title('Imagem sem
partículas');
subplot(2,3,4); imshow(imMudasPreenchidas); title(['número de mudas:
',num2str(NumeroMudas), ', Erro: ' num2str(ErroMaxG) ,' %' ]);
```