

---

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**CENTRO DE TECNOLOGIA E GEOCIÊNCIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E**  
**TECNOLOGIAS DA GEOINFORMAÇÃO**

---

JOSÉ ÉRICO DO NASCIMENTO BARROS

**ANÁLISE DE FALHAS NO CULTIVO DE CANA DE AÇÚCAR A PARTIR DE**  
**IMAGENS DE AERONAVE**  
**REMOTAMENTE PILOTADA**



Recife  
2018

---

JOSÉ ÉRICO DO NASCIMENTO BARROS

**ANÁLISE DE FALHAS NO CULTIVO DE CANA DE AÇÚCAR A PARTIR DE  
IMAGENS DE AERONAVE  
REMOTAMENTE PILOTADA**

Dissertação de Mestrado apresentado ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como parte do requisito para obtenção de grau de mestre.

**Área de Concentração:** Cartografia e Sistemas de Geoinformação.

**Orientadora:** Prof. Dra. Ana Lúcia Bezerra Candeias

Recife

2018

Catálogo na fonte

Bibliotecária Valdicèa Alves, CRB-4 / 1260

B277a Barros, José Érico do Nascimento.

Análise de falhas no cultivo de cana de açúcar a partir de imagens de aeronave remotamente pilotada – Pernambuco, Brasil / José Érico do Nascimento. - 2018.

56 folhas. Il. Tab.

Orientador(a): Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Lúcia Bezerra Candeias.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Ciência Geodésicas, 2018.

Inclui Referências.

1. Engenharia cartográfica. 2. Sistema de informação geográfica. 3. Agricultura de precisão. 4. Aeronave remotamente pilotada. 5. Ortomosaico. 6. Cana de açúcar. I. Candeias, Ana Lúcia Bezerra (Orientadora). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2018-501

JOSÉ ÉRICO DO NASCIMENTO BARROS

**ANÁLISE DE FALHAS NO CULTIVO DE CANA DE AÇÚCAR A PARTIR DE  
IMAGENS DE AERONAVE  
REMOTAMENTE PILOTADA**

Dissertação de Mestrado apresentado ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como parte do requisito para obtenção de grau de mestre.

Aprovado em: 30/08/2018

**BANCA EXAMINADORA**

---

Profa. Dra. Ana Lúcia Bezerra Candeias (Orientador)  
Universidade Federal de Pernambuco

---

Prof. Dr. João Rodrigues (Examinador Interno)  
Universidade Federal de Pernambuco

---

Profa. Dra. Valéria Sandra de Oliveira Costa (Examinadora Externa)  
PNPD – PRODEMA (Universidade Federal de Pernambuco )

## **AGRADECIMENTOS**

A Deus por ter me dado saúde, força e paciência para superar as dificuldades.

A esta Universidade, seu Corpo Docente, Direção e Administração, que oportunizaram a janela, que hoje vislumbro um horizonte superior, eivado pela acendrada confiança no mérito e ética aqui presentes.

À minha orientadora Ana Lúcia Bezerra Candeias, pelo suporte, pelas suas correções e incentivos.

Aos meus colegas de mestrado, pelo companheirismo.

A Leonardo Malta, por ter cedido em nome da LM Engenharia, todos os dados com os quais pude realizar este trabalho.

Também aos colegas da Plonus Soluções em Engenharia e Meio Ambiente pelo auxílio e aprendizado que tenho, em especial a Ivan Dornelas pelas correções e auxílio no estudo aqui apresentados.

Aos meus pais, pelo amor, incentivo e apoio incondicional nesta caminhada tão árdua.

E a todos que direta ou indiretamente fizeram parte da minha formação.

## RESUMO

A Agricultura de Precisão visa o gerenciamento detalhado do sistema de produção agrícola. Os sensores de alta resolução orbital possuem limitações tais como a resolução temporal e o recobrimento de nuvens. O RPA (*Remotely Piloted Aircraft* ou Aeronave Remotamente Pilotada) surge como opção para auxiliar na Agricultura de Precisão, pois a obtenção das imagens pode ser decidida conforme a necessidade do estudo do plantio e, portanto, não tendo mais a limitação da resolução temporal de imageamento. Além disso, o problema de recobrimento de nuvens não é mais um problema, pois existe a vantagem de poder planejar o voo para uma altitude inferior às nuvens presentes na área. Este estudo mostra como a obtenção dos produtos de uma base cartográfica, produzida a partir de um aerolevanteamento de uma Aeronave Remotamente Pilotada possibilita detectar falhas no cultivo da cana de açúcar a partir do ortomosaico gerado pelo processamento tridimensional. A coleta de informações sobre a distribuição geográfica nos dá suporte para o desenvolvimento deste trabalho, visando a subsidiar o gerenciamento de recursos privados na agricultura, possibilitando a melhoria da produtividade.

Palavras-chave: Sistema de informação geográfica. Agricultura de precisão. Aeronave remotamente pilotada. Ortomosaico. Cana de açúcar.

## **ABSTRACT**

Precision Agriculture aims at the detailed management of the agricultural production system. High resolution orbital sensors have limitations such as temporal resolution and cloud cover. The RPA (Remotely Piloted Aircraft) appears as an option to assist in Precision Agriculture, since the acquisition of the images can be decided according to the need of the study of the planting and, therefore, no longer having the limitation of the temporal resolution of imaging. In addition, the cloud cover problem is no longer a problem as there is the advantage of being able to plan the flight to a lower altitude than the clouds present in the area. This study shows how the obtaining of the products of a cartographic base, produced from an aerial survey of a Remotely Piloted Aircraft, makes it possible to detect failures in sugarcane cultivation from orthomosaic generated by three - dimensional processing. The collection of information on the geographic distribution gives us support for the development of this work, aiming to subsidize the management of private resources in agriculture, enabling the improvement of productivity.

Keywords: Geographic information system. Precision agriculture. Remotely piloted aircraft. Ortomosaic. Sugar cane.

## LISTA DE FIGURAS

Figura 1 -	Curvas de distribuição do número de falhas pelo tamanho	18
Figura 2 -	Modelo IHS	22
Figura 3 -	RPA utilizado	26
Figura 4 -	Fluxograma do trabalho	28
Figura 5 -	Localização do município de Paudalho - PE	31
Figura 6 -	Distribuição dos pontos de controle em campo do aerolevanteamento	33
Figura 7 -	Materialização dos pontos de controle de campo	34
Figura 8 -	Linhas de voo e sobreposição de fotografias	35
Figura 9 -	Modelo Digital de Terreno	36
Figura 10 -	Identificação da amostra selecionada para a pesquisa	38
Figura 11 -	Amostra com as curvas de nível	39
Figura 12 -	Detalhe da vetorização das linhas de plantio de cana de açúcar	40
Figura 13 -	Linhas de plantio vetorizadas a partir do ortomosaico	40
Figura 14 -	Distribuição de frequências e estatísticas das linhas de plantio	41
Figura 15 -	Imagem original (a) e as Bandas Cor (b), Intensidade (c) e Saturação (d)	42
Figura 16 -	Banda H (cor) resultante da transformação RGB – IHS	42
Figura 17 -	Vegetação extraída do algoritmo K-Médias	44
Figura 18 -	Comparativo do resultado da classificação não supervisionada	44
Figura 19 -	Vegetação extraída do algoritmo Maxver	45
Figura 20 -	Comparativo do resultado da classificação supervisionada	46
Figura 21 -	Exclusão dos polígonos de vegetação extraídos através da imagem raster	47
Figura 22 -	Analogia do geoprocessamento utilizado no cálculo das falhas	48
Figura 23 -	Falhas resultantes do plantio usando algoritmo K-Médias	48
Figura 24 -	Falhas resultantes do plantio usando algoritmo Maxver	49
Figura 25 -	Detalhe de um dos resultados do geoprocessamento das falhas na cana de açúcar	49
Figura 26 -	Gráfico da quantidade de falhas no algoritmo K-Médias	52
Figura 27 -	Gráfico da quantidade de falhas no algoritmo Maxver	52

Figura 28 - Gráfico da quantidade e comprimento das falhas para os 53 algoritmos MaxVer e K-Médias

## LISTA DE TABELAS

Tabela 1 -	Quantitativo das falhas por tamanho.	50
Tabela 2 -	Diferença entre os classificadores.	51

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>12</b>
<b>2</b>	<b>OBJETIVOS.....</b>	<b>15</b>
2.1	OBJETIVO GERAL.....	15
2.2	OBJETIVOS ESPECÍFICOS.....	15
<b>3</b>	<b>REFERENCIAL TEORICO.....</b>	<b>16</b>
3.1	AGRICULTURA DE PRECISÃO.....	16
<b>3.1.1</b>	<b>Avaliação de falhas nas linhas de cana de açúcar.....</b>	<b>17</b>
3.2	CLASSIFICAÇÃO DIGITAL.....	19
<b>3.2.1</b>	<b>Classificação supervisionada.....</b>	<b>19</b>
<b>3.2.2</b>	<b>Classificação não supervisionada.....</b>	<b>20</b>
<b>3.2.3</b>	<b>Transformação Sistema RGB – IHS.....</b>	<b>21</b>
<b>3.2.4</b>	<b>Classificação Supervisionada por Máxima Verossimilhança.....</b>	<b>22</b>
3.3	GEOPROCESSAMENTO.....	23
3.4	COMPONENTES DE UMA AERONAVE REMOTAMENTE PILOTADA.....	23
<b>3.4.1</b>	<b>Tipos de RPA.....</b>	<b>24</b>
<b>3.4.2</b>	<b>Regulamentação do uso do RPA.....</b>	<b>25</b>
3.5	Pesquisas com análise de falhas em cana de açúcar.....	26
<b>4</b>	<b>RESULTADOS.....</b>	<b>28</b>
4.1	MATERIAIS E MÉTODOS.....	28
<b>4.1.1</b>	<b>Localização da área de estudo.....</b>	<b>30</b>
<b>4.1.2</b>	<b>Planejamento do voo.....</b>	<b>32</b>
<b>4.1.3</b>	<b>Apoio terrestre.....</b>	<b>32</b>
4.2	PROCESSAMENTO DOS DADOS DE VOO.....	34
4.3	ANÁLISE DAS FALHAS.....	37
<b>4.3.1</b>	<b>Seleção e preparação de Amostra.....</b>	<b>37</b>

4.3.2	Transformação RGB – IHS.....	41
4.3.3	Classificação não supervisionada.....	43
4.3.4	Classificação supervisionada.....	45
4.3.5	Procedimento de extração de feições.....	46
5	CONCLUSÕES.....	54
	REFERÊNCIAS.....	55

# 1 INTRODUÇÃO

Nos dias atuais, para maximizar a produtividade dos cultivos na agricultura, estão sendo desenvolvidas metodologias, denominadas de Agricultura de Precisão, que demanda o conhecimento detalhado e prévio de informações geográficas e georreferenciadas dessas atividades. Com essas técnicas busca-se a redução das perdas de produção e o conhecimento de uma série de fatores que contribuem decisivamente nos resultados.

Um importante instrumento na aquisição de dados e informações para uma Agricultura de Precisão são veículos aéreos, de pequenas dimensões, que são controladas remotamente, e que possuem embarcados sensores que registram respostas espectrais de alvos em solo.

Esses veículos, ou aeronaves, por serem controladas remotamente, são classificadas como não tripuladas e recebem a denominação de Veículo Aéreo Não Tripulado (VANT). Popularmente esses equipamentos são conhecidos como Drones, que traduzido literalmente do inglês, significa zangão. Essa denominação foi atribuída devido ao som característico produzido pelo movimento de suas hélices.

A legislação que regulamenta o uso desses equipamentos, refere-se a eles como Aeronave Remotamente Pilotada, recebendo a sigla RPA (*Remotely Piloted Aircraft*). Nesta pesquisa foi adotada a nomenclatura de RPA para este tipo de aeronave, visto que é a forma mais recente ao qual foi atribuída.

A evolução tecnológica desses equipamentos e a facilidade de acesso a seus componentes e a sensores diversos, tem proporcionado aplicação dos VANTs em novas áreas como na agricultura, onde essa tecnologia auxilia na identificação de anormalidades e na condução de tratamentos culturais em lavouras comerciais, visando maximizar a produtividade através da prática da Agricultura de Precisão, ou mesmo através da exploração de novas áreas (ANTUNIASSI e SALVADOR, 2002).

Segundo o Ministério da Agricultura Pecuária e Abastecimento (MAPA, 2011), Agricultura de Precisão compreende um conjunto de técnicas e metodologias que visam aperfeiçoar o manejo das culturas e a utilização dos insumos agropecuários, proporcionando máxima eficiência econômica.

As técnicas associadas à Agricultura de Precisão permitem o uso racional dos corretivos, fertilizantes e agrotóxicos garantindo a redução dos impactos ambientais decorrentes da atividade agropecuária.

Imagens obtidas por sensores orbitais possuem menor resolução espacial, são mais caras e sofrem influências importantes da passagem do sinal pela atmosfera (MOREIRA, 2003).

De uma forma geral, imagens geradas por sensores embarcados em VANT têm etapas de obtenção e processamento mais breves, maior resolução espacial, maior resolução temporal e facilidades de operação, possibilitando monitoramento periódico com menor custo, maior detalhamento, e menor intervalo de tempo entre as coletas (MEDEIROS *et al.*, 2008).

Nas últimas décadas verificou-se um avanço vertiginoso da informática e da automação em diversas áreas, incluindo a área agrícola. Essas tecnologias contribuem para uma melhoria das condições de trabalho e promovem a qualidade, a produtividade e a competitividade, além de contribuírem na preservação ambiental. No caso da agricultura, desde a década de 70, houve um aumento acentuado do uso da eletrônica para supervisionar e para controlar automaticamente as funções mais importantes das máquinas e implementos.

A utilização da tecnologia de Sensoriamento Remoto (SR), destacadamente a tecnologia de VANT, constitui-se em um importante meio para a obtenção de imagens em locais inóspitos e de difícil acesso. Além do mais, devido à operação da unidade aérea por controle remoto, não há a necessidade de profissionais embarcados, eliminando risco ao operador de câmera ou ao piloto (WATTS, 2012).

Falhas no plantio são fatores que contribuem com o decréscimo da produtividade na cana de açúcar. Determina-se uma falha, a projeção da distância entre duas canas consecutivas ao longo da linha de plantio. Ao longo dos anos, foi empregada metodologias de mensuração das falhas de forma manual, sendo bastante trabalhosa a extração dessas informações, além de estabelecerem uma quantificação de forma probabilística.

Essa pesquisa desenvolveu uma proposta para extração automática de falhas do plantio de cana de açúcar utilizando processamento de imagens e ortomosaicos gerados a partir de dados obtidos por RPAs. Essa automatização busca contribuir

para o controle da produção do plantio com a identificação de possíveis locais com problemas no solo ou decorrentes da irrigação da área.

## 2 OBJETIVOS

O objetivo deste estudo é analisar com apoio de técnicas de processamento de imagens a quantificação das falhas encontradas em uma plantação de cana de açúcar a partir de um ortomosaico, oriundo do aerolevanteamento com uma Aeronave Remotamente Pilotada.

### 2.1 OBJETIVO GERAL

Detectar falhas no cultivo da cana de açúcar a partir do ortomosaico gerado pelo mapeamento aéreo por Aeronave Remotamente Pilotada.

### 2.2 OBJETIVOS ESPECÍFICOS

- Verificar a qualidade dos produtos gerados pelo aerolevanteamento de uma Aeronave Remotamente Pilotada;
- Analisar as técnicas de Processamento de Imagem e Geoprocessamento para extração das falhas do cultivo de cana de açúcar;
- Comparar os resultados das falhas através de gráficos e analisar os comportamentos de acordo com a metodologia abordada.

### 3 REFERENCIAL TEORICO

Na agricultura, falhas são espaços vazios sem colmos nas linhas de cana de açúcar, sendo sua ocorrência associada à diminuição da produtividade. Na implantação da cultura é dada grande importância a falhas de brotação, ou seja, no seu plantio, outros fatores até a colheita, como o tipo e estado da lâmina de corte das colhedoras, provocam danos às soqueiras. Assim, ervas invasoras, estiagem, baixa temperatura na época de plantio, ataque de pragas subterrâneas de rizoma, pisoteio das soqueiras provocam falhas, sendo importante o desenvolvimento de técnicas para a quantificação.

O método de avaliação de falhas segundo Stolf *et al.* (2016), desenvolvido na década de 1980 e início da década de 1990, permite a obtenção do índice de falhas e uma previsão de perdas de produtividade em cana de açúcar. O método tem sido utilizado por várias empresas agrícolas em levantamento convencional, terrestre, utilizando trena métrica dentro do canavial (STOLF *et al.*, 2016). É possível verificar que, com as mudanças ocorridas no plantio da cana de açúcar, a ocorrência de falhas no canavial tornou-se um aspecto importante a ser considerado.

#### 3.1 AGRICULTURA DE PRECISÃO

A Agricultura de Precisão é um tema abrangente, sistêmico e multidisciplinar. Ela não se limita a algumas culturas nem a algumas regiões. Trata-se de um sistema de manejo integrado de informações e tecnologias, fundamentado nos conceitos de que as variabilidades de espaço e tempo influenciam nos rendimentos dos cultivos.

A Agricultura de Precisão visa o gerenciamento mais detalhado do sistema de produção agrícola como um todo, não somente das aplicações de insumos ou de mapeamentos diversos, mas de todos os processos envolvidos na produção. Esse tipo de agricultura não está relacionado somente ao uso de ferramentas de alta tecnologia, pois os seus fundamentos podem ser empregados no dia a dia das propriedades pela maior organização e controle das atividades, dos gastos e produtividade em cada área.

O emprego da diferenciação ocorre na divisão e localização das lavouras nas propriedades, na divisão dos talhões ou piquetes, ou simplesmente, na identificação de manchas que diferem do padrão geral. A Agricultura de Precisão é representada por três pontos que convergem em excelência de resultados: Revolução gerencial, Tecnologia de Informação e Agregação de valor à produção. É fator determinante que estes três pontos sejam trabalhados em conjunto para que se estabeleça o aprimoramento da produtividade, da qualidade, do volume a ser produzido e da redução de preço dos produtos para competir no mercado interno e externo. Portanto, tecnologia, planejamento e gerenciamento são os fundamentos da Agricultura de Precisão.

Questões relacionadas com aplicações potenciais na agricultura, tipos de sensores e aviões, as limitações de cada um e os resultados de utilização são avaliados. A intenção ao descrever os problemas e propor recomendações não é sugerir um conjunto de questões conclusivas, pois a área está em pleno desenvolvimento, mas sim para estimular a discussão, construir consensos e promover o planejamento estratégico entre as organizações que têm uma participação no surgimento de VANT em Agricultura de Precisão.

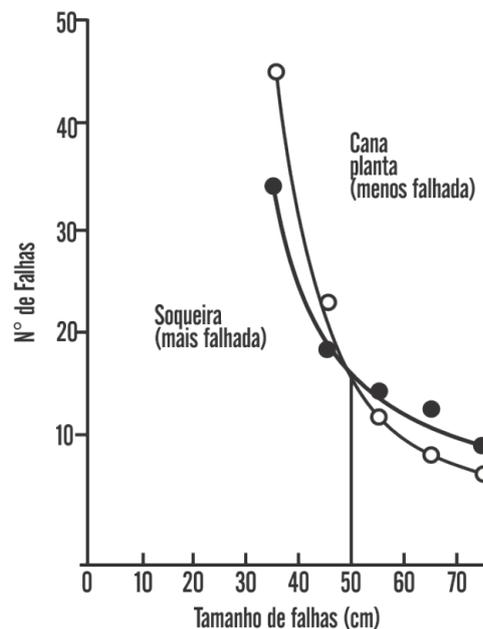
### **3.1.1 Avaliação de falhas nas linhas de cana de açúcar**

No plantio da cana de açúcar é colocado um número grande de gemas nos sulcos. A formação de uma falha ocorre quando um número de gemas consecutivas deixa de brotar, podendo-se considerar um fenômeno aleatório, com distribuição decrescente com o tamanho da falha, pois a probabilidade de ocorrer uma sequência cada vez maior de gemas consecutivas não brotadas diminui exponencialmente (STOLF *et al.*, 2016).

Não existe canavial sem falhas, sendo uma ocorrência natural, apresentando-se de diferentes tamanhos. A Figura 1 apresenta dois exemplos de curvas de distribuição de falhas em canaviais. Um aspecto marcante é que o número de falhas por 100 m de linha diminui exponencialmente para as classes maiores. Assim, se medirmos falhas a partir de um tamanho muito grande praticamente não haverá falhas para medir. Por outro lado, se decidirmos medir a partir de um tamanho de falhas muito pequeno, o volume de trabalho na medida aumenta exponencialmente. Assim, a

questão de se estabelecer um tamanho, a partir do qual se deve medir, surge como uma necessidade. Ao comparar as curvas de distribuição de dois canaviais, cana planta (menos falhada) e soqueira (mais falhada), verificou-se que o canavial melhor, menos falhado, apresentava mais falhas nas classes menores e menos falha nas classes maiores. O ponto de cruzamento entre as curvas é o tamanho de falha acima do qual devemos medir para se obter a maior distinção entre os canaviais. O ponto encontrado foi ao redor de 0,5 m, estabelecendo-se o valor mínimo acima do qual se deve considerar como falha no plantio (STOLF *et al.*, 2016).

Figura 1 - Curvas de distribuição do número de falhas pelo tamanho



Fonte: Stolf *et al.* (2016).

A metodologia clássica de identificação e mensuração de falhas na lavoura de cana de açúcar é feita por agricultores a partir de levantamento manual. A amostragem é realizada a partir de 90 dias após o plantio, no momento que a cultura já está estabelecida. É considerada uma falha, a projeção da distância entre dois colmos consecutivos ao longo da linha de cana, distância essa, maior que 50 cm, medida de centro a centro do plantio ao nível do solo.

Para estabelecermos estatisticamente o índice de percentual de falhas, basta somar o comprimento total de falhas maiores que 0,5 m em um trecho de linha de cana e dividir pelo comprimento do trecho considerado x 100. Recomenda-se medir um total mínimo de cerca de 200 m de linha por talhão (10 ha) dividido em quatro amostras

de 50 m, podendo aumentar as repetições para esse total (8 ou 10 amostras de 20 m) (STOLF *et al.*, 2016). Este procedimento além de muito trabalhoso, pode não ser muito confiável quando analisamos que um talhão pode variar muito de tamanho e a amostragem não ser de tamanho suficiente.

Para esta metodologia, iremos adotar uma metodologia que automatize os resultados e permita uma parametrização estatística muito superior ao método tradicional realizado atualmente e que se mostra pouco eficaz em relação aos resultados alcançados.

## 3.2 CLASSIFICAÇÃO DIGITAL

De acordo com Dainese (2001), a classificação digital de imagens orbitais consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe ou um tema que descreve um objeto no mundo real. A classificação é dividida nos seguintes passos: Seleção de feições de interesse, escolha do método padrão de comparação, ou seja, a classificação propriamente dita e a determinação da exatidão do mapa gerado.

A seleção de feições de interesse é, na verdade, o reconhecimento das respostas espectrais das classes. Os métodos de classificação digital podem ser agrupados em função da presença ou não de uma fase de treinamento onde o analista interage com o computador.

Os métodos de classificação podem ser divididos em classificadores por pixel ou por regiões e podem levar em conta uma ou mais bandas da imagem (no caso de imagens multiespectrais). Os classificadores por pixel utilizam a informação espectral de cada pixel isolado para encontrar regiões homogêneas definidas como classes e podem também ser divididos em supervisionados e não-supervisionados.

### 3.2.1 Classificação supervisionada

O método de classificação é dito supervisionado quando existe um conhecimento prévio de algumas áreas em que se deseja trabalhar. O classificador opera com base na distribuição de probabilidade de cada classe selecionada. Nesse caso, o

analista inicialmente treina o classificador, para depois associar os pixels a uma determinada classe, através de regras estatísticas preestabelecidas.

O método da Máxima Verossimilhança (Maxver) é o mais utilizado em sensoriamento remoto dentro da abordagem estatística. É um método considerado paramétrico, pois envolve parâmetros da distribuição gaussiana multivariada e é supervisionado, pois estima estes parâmetros através das amostras de treinamento (ERBERT, 2001).

Este método considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos. Este classificador avalia a probabilidade de um determinado pixel pertencer a uma categoria a qual ele tem maior probabilidade de associação (INPE 2002).

### **3.2.2 Classificação não supervisionada**

O método é dito não supervisionado quando o classificador não utiliza nenhum conhecimento sobre as classes existentes na imagem e define, sem a interferência do analista, a estratificação da cena, atribuindo a cada pixel uma determinada classe. Tal abordagem corresponde à técnica de segmentação de imagens, onde as mesmas são divididas em certas classes sem conhecimento prévio. Neste tipo de classificação, o algoritmo baseia-se na análise de agrupamentos onde são identificadas no espaço de atributos as manchas formadas por pixels com características espectrais similares.

Definem-se então, através de um limiar estabelecido pelo analista, quais as concentrações de pixels que devem ser tratadas como grupos distintos. O algoritmo define estas classes com base em regras estatísticas pré-selecionadas. Entre os algoritmos utilizados neste método temos o K-Médias.

O K-Médias agrupa os dados em K dimensões do espaço, onde K refere-se ao número de bandas espectrais e/ou imagens envolvidas. O objetivo deste procedimento é agrupar os pixels de características espectrais mais similares, a partir de medidas de menor distância euclidiana entre um pixel e os centros de gravidade das classes definidas anteriormente. Os parâmetros de entrada são o número de classes e de iterações.

### 3.2.3 Transformação Sistema RGB - IHS

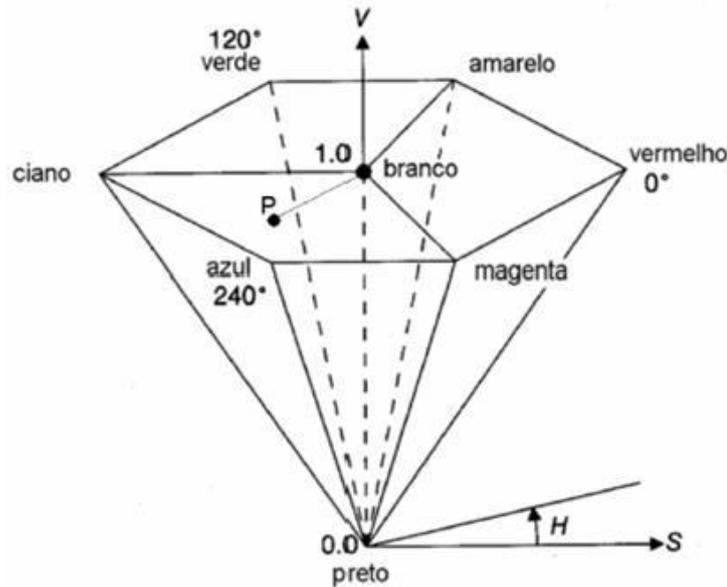
Para descrever as propriedades dos objetos de uma imagem normalmente utilizam-se proporções de vermelho, verde e azul. Este é o chamado sistema RGB. Mas podem-se utilizar componentes de intensidade, matiz e saturação para descrever sensações de brilho, cor e pureza da cor respectivamente. Este sistema é chamado IHS (*intensity, hue, saturation*). O resultado visual da cor na manipulação da intensidade e do matiz é o mesmo que o da manipulação no RGB (DEBIASI *et al.*, 2007).

A maneira de visualizar dados espectrais usando um computador é associar às leituras do contador digital em diferentes bandas as intensidades de cor no monitor, associando à energia refletida dos objetos aos níveis de cinza ou tonalidades. O monitor representa as cores pela combinação aditiva das cores básicas: vermelho, verde e azul, do que decorre o nome RGB (*Red, Green, Blue*).

Qualquer cor a ser representada na tela é o resultado da combinação destas três cores básicas. Isto resulta numa quantidade limitada de cores que é, porém, muito grande em relação à capacidade de percepção do olho humano. As cores podem ser representadas por um vetor tridimensional (RGB) e os valores digitais possíveis dependem da resolução radiométrica da imagem. Para uma imagem de oito bits, o espaço RGB assume a forma de um cubo de 256 valores digitais para cada um dos eixos (CENTENO e RIBEIRO, 2007).

Com a finalidade de descrever as cores usando termos mais comuns ao ser humano foram criados sistemas alternativos, como o sistema IHS: Intensidade (*Intensity*), tonalidade ou matiz (*Hue*) e saturação (*Saturation*). Matiz é o aspecto colorido da impressão visual, que corresponde ao estímulo da retina por determinados comprimentos de onda. A saturação se refere ao grau de pureza da cor predominante, ou também é descrita como o conteúdo de branco de um estímulo percebido. Finalmente, a intensidade corresponde ao total de energia incidente em todos os comprimentos de onda percebidos pelo olho (CENTENO e RIBEIRO, 2007). Uma representação gráfica é mostrada na Figura 2.

Figura 2 - Modelo IHS



Fonte: ENVI (2000)

Na Figura 2, temos a distância a partir ponto preto ao longo da linha de cinza na vertical representa a intensidade de cada pixel. As componentes da cor: matiz e saturação são definidos geometricamente pelo hexágono, sendo a matiz determinada pelo ângulo em torno do hexágono e a saturação pela distância do ponto ao centro à borda do hexágono. Pontos distantes do centro representam cores mais puras do que os próximos ao centro.

### 3.2.4 Classificação Supervisionada por Máxima Verossimilhança

Este é o método tradicional mais comumente utilizado quando é necessária a obtenção de classes informacionais a partir de imagens de sensores remotos. A distribuição espectral das classes de uso do solo é considerada como sendo gaussiana ou normal, isto é, objetos pertencentes à mesma classe apresentarão resposta espectral próxima à média de valores para aquela classe.

Este método parte do princípio que a classificação errada de um pixel não tem maior significado do que a classificação errada de qualquer outro pixel na imagem. O método considera a ponderação das distâncias médias, utilizando parâmetros estatísticos de distribuição dos pixels dentro de uma determinada classe (CRÓSTA, 1993).

Para a obtenção de um bom resultado com esta classificação é necessária a escolha de um número razoavelmente elevado de pixels para cada amostra de treinamento da classe, e que estes tenham uma distribuição estatística próxima da distribuição normal (CRÓSTA, 1993).

### 3.3 GEOPROCESSAMENTO

O geoprocessamento procura abstrair o mundo real, transferindo ordenadamente as suas informações para o sistema computacional. Esta transferência é feita sobre bases cartográficas, através de um sistema de referência apropriado. Estes conceitos são importantes para o usuário que pretende trabalhar com esta tecnologia. Um sistema de geoprocessamento é, geralmente, destinado ao processamento de dados referenciados geograficamente (ou georreferenciados), desde a sua coleta até a geração de saídas na forma de mapas convencionais, relatórios, arquivos digitais, etc, devendo prever recursos para sua estocagem, gerenciamento, manipulação e análise (DAINESE, 2001).

O uso do geoprocessamento nesta pesquisa servirá para retirarmos a informação resultante dos processamentos digitais envolvidos nas etapas descritas deste trabalho. A transformação dos dados originais raster em dados vetoriais implica no uso de técnicas descritas neste estudo para extrair os resultados presentes nas análises das classificações supervisionadas e não-supervisionadas.

### 3.4 COMPONENTES DE UMA AERONAVE REMOTAMENTE PILOTADA

Além da aeronave, o RPA é composto de uma estação de controle em solo, o *Ground Control Station* (GCS) através da qual é possível planejar a missão a ser executada e acompanhar todo o trabalho realizado remotamente. O VANT possui também um Sistema de Posicionamento Global (GPS) acoplado, assim como, uma Unidade de Navegação Inercial.

O veículo não aceita comandos de movimento diretamente ligados pelo GPS, devido a grande margem de erro deste, recorrendo a uma Unidade de Navegação Inercial (INU) garantindo uma melhor precisão da posição. Uma Unidade de Navegação Inercial é um sistema de navegação que integra as acelerações em Norte/Sul,

Leste/Oeste por meio de sensores inerciais, determinando a posição. Segue abaixo listada algumas vantagens da navegação inercial: não necessita de informação exterior, não requer emissões ou recepções de sinais e é imune a interferências.

O piloto automático ou AFCS (*Autonomous Flight Control System*) é um pacote integrado normalmente fornecido pelo fabricante. O AFCS recebe o controle da estação de solo GCS (*Ground Control Station*) através da telemetria de controle do sistema que atua de forma autônoma. Os Veículos Aéreos Não Tripulados têm como componente principal um sistema de controle capaz de manter a aeronave estabilizada e de executar manobras que a conduza através de uma rota e missão selecionada.

Existem sistemas disponíveis gratuitamente na *internet*, que podem ser configurados por qualquer pessoa e funcionam perfeitamente, inclusive operados por dispositivos como *Tablets* e *Smartphones* (NERIS, 2001).

### **3.4.1 Tipos de RPA**

De acordo com Medeiros *et al.* (2007), os veículos Aéreos Não Tripulados (VANT) são pequenas aeronaves, sem qualquer tipo de contato físico direto, capazes de executar diversas tarefas, tais como monitoramento, reconhecimento tático, vigilância e mapeamento entre outras. As aeronaves não tripuladas têm sido projetadas para vários tipos de missão, mas o relato que se tem é que a origem desses veículos está ligada à área militar, como alvos aéreos manobráveis, reconhecimento tático, guerra eletrônica, entre outros. Além do alcance e altitude, diferem em asa fixa ou rotativa. O de asa rotativa pode ser do tipo helicóptero convencional ou multirotor.

O Veículo Aéreo Não Tripulado do tipo multirotor é uma plataforma aérea com sofisticada eletrônica embarcada que permite transportar diferentes sistemas de captura de imagens. Sua instrumentação e sistemas de controle permitem voos com alta estabilidade com reduzido tempo de treinamento operacional. O VANT de pequeno porte do tipo asa fixa também é uma opção interessante para a área agrícola. No entanto são também muito susceptíveis aos ventos fortes. Mas de uma forma geral é o que menos apresenta problemas de operação.

### **3.4.2 Regulamentação do uso do RPA**

A Agência Nacional de Aviação Civil (ANAC) aprovou, no dia 02 de maio de 2017, o regulamento especial para utilização de aeronaves não tripuladas, popularmente chamadas de drones. A norma (Regulamento Brasileiro de Aviação Civil Especial – RBAC –E nº 94) está publicada no Diário Oficial da União. Segundo a ANAC (2017), o novo regulamento dividiu as aeronaves não tripuladas em aeromodelos, drones usados para fins recreativos, e Aeronaves Remotamente Pilotadas, drones utilizados para operações comerciais, corporativas ou experimentais.

Pela regra geral, os drones com mais de 250 g só poderão voar em áreas distantes de terceiros, com total responsabilidade do piloto operador e conforme regras de utilização do espaço aéreo. Os drones de uso comercial, corporativo ou experimental (RPA) foram categorizados em três classes, de acordo com o peso máximo de decolagem do equipamento: Classe 1 com peso acima de 150 kg, Classe 2 com peso acima de 25 kg e abaixo ou igual a 150 kg e Classe 3 com Peso abaixo ou igual a 25 kg;

A norma determina que as RPAs pertencentes à Classe 3, operem em até 400 pés (120m) acima da linha do solo e em linha de visada visual. Não precisarão ser de projeto autorizado, mas deverão ser cadastrados na ANAC. O Modelo utilizado na pesquisa pertence à Classe 3 e está cadastrado no Sistema da ANAC. Vale salientar que o voo efetuado foi realizado no dia 26 de junho de 2016, quase 1 ano antes da nova regulamentação ser registrada. O modelo RPA utilizado foi o BATMAP (Figura 3) e possui as seguintes características segundo o site do fabricante: estrutura em EPO e Fibra de Carbono, autonomia de 90 minutos, câmera RGB de 24,3 megapixels (SONY A6000), lente de 16 mm de foco fixo, raio de operação de 6 km, velocidade de cruzeiro de 45 km/h, teto operacional de 3500 m, decolagem, operação e pouso automáticos, peso de 2,6 kg e envergadura de 1950 mm.

Figura 3 - RPA utilizado



Fonte: Batmap

Os produtos gerados pelo mapeamento aéreo formam uma base cartográfica da área. Através desta base podem ser realizadas diversas análises e operações. Uma base cartográfica é um produto georreferenciado da área de interesse. Antigamente, estes produtos eram cartas impressas em escala e, com o avanço tecnológico, os mapas foram perdendo sua função estática e hoje temos mapas dinâmicos e totalmente interativos. As bases cartográficas geradas pelos RPAs são: Ortomosaico, Modelo Digital de Superfície, Modelo Digital do Terreno e Curvas de nível.

### 3.5 PESQUISAS COM ANÁLISE DE FALHAS EM CANA DE AÇÚCAR

Os processamentos das imagens obtidas com um RPA, com sobreposições adequadas, mesmo de áreas consideradas difíceis, de forma automática, são considerados satisfatórios. Testes de qualidade quanto à precisão mostram que é possível gerar produtos com escala de até 1:400 (SILVA *et al.* 2014).

A utilização de um sistema de sensor fotoelétrico em aeronaves não tripuladas permitiu o desenvolvimento e testes de medidas em falhas de plantio de cana de açúcar e substituiu o atual método de monitoramento manual com a vantagem de amostragem intensiva e maior densidade de informação. As informações adquiridas nas falhas da cana de açúcar podem ser representadas em mapas que permitam a visualização de áreas que exigem intervenção local após o plantio ou uma decisão

de replantação de toda a área quando é atingida uma lacuna limiar (MOLIN e VEIGA, 2016).

Utilização de procedimento que permite o reconhecimento de alvos em imagens coloridas a partir da identificação de cenas contendo possíveis alvos é possível com imagens obtidas por câmara de vídeo de baixo custo acoplada em plataforma não estabilizada de VANT. Há uma viabilidade da utilização de procedimento para reconhecimento de alvos (FIGUEIRA e VOLOTÃO, 2013).

Imagens tomadas por plataformas de Sensoriamento Remoto de baixa altitude ou RPAs são uma alternativa potencial, dado seu baixo custo de operação em monitoramento ambiental, alta resolução espacial e temporal e sua alta flexibilidade na aquisição de imagens (ZHANG e KOVACS, 2012).

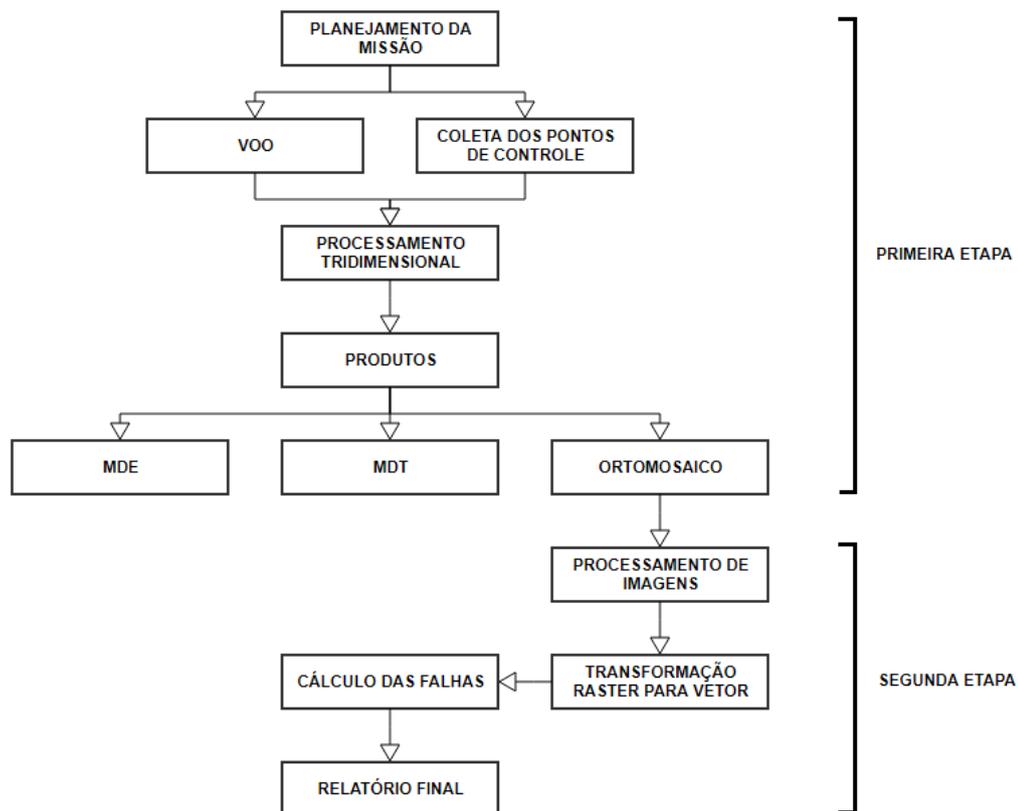
## 4 RESULTADOS

Nesta sessão são descritas as atividades que foram executadas na elaboração deste estudo.

### 4.1 MATERIAIS E MÉTODOS

O estudo aqui apresentado consiste no planejamento e execução de um aerolevantamento feito por uma Aeronave Remotamente Pilotada com aplicação para Agricultura de Precisão. Foram executadas em duas etapas que serão descritas a seguir. O fluxograma da Figura 4 apresenta o procedimento das etapas desenvolvidas para o trabalho aqui apresentado.

Figura 4 - Fluxograma do trabalho



Fonte: O Autor (2018)

A primeira etapa do estudo consistiu na aquisição dos dados, realizado em um voo com o RPA modelo BATMAP de propriedade da LM Engenharia. Em um projeto de

aerolevanteamento com RPA são obtidas várias imagens. A partir de um *software* de processamento de dados, estas imagens foram unificadas em uma única imagem cobrindo toda área de interesse. Em sequência, esta imagem foi georreferenciada, ou seja, cada pixel da imagem possui suas coordenadas conhecidas possibilitando a realização de medidas nesta imagem. Para fins de simplificação, denota-se nesta pesquisa ortomosaico como mosaico de ortofotos.

Após o aerolevanteamento, efetuou-se o processamento das imagens de modo a adquirir os dados resultantes do voo. Para o processamento do voo, foi utilizado o *software PhotoScan* da *Agisoft*. De acordo com o fabricante, o *PhotoScan* proporciona uma fototriangulação aérea e terrestre, geração de nuvem de pontos e modelos poligonais triangulares 3D, MDT, MDS e ortofotos verdadeiros. O *software* utiliza pontos homólogos das imagens de forma que possa ser criado um modelo tridimensional. Após todas as etapas relativas ao processamento do aerolevanteamento, prosseguiu-se com a etapa seguinte que foi o tratamento dos produtos obtidos, em especial ao ortomosaico.

O procedimento de tratamento do ortomosaico obtido do processamento tridimensional consistiu no tratamento inicial das imagens (realce, correção gama, contraste, etc.), a fim de melhorar o aspecto visual. Foi realizado neste estudo a transformação RGB para IHS e a classificação não supervisionada dos objetos pelo método K-Médias e também a classificação supervisionada pelo método Maxver.

A classificação supervisionada por Máxima Verossimilhança foi usada para extrair as feições de vegetação convenientes ao processo. Foi coletado um conjunto de amostras relativas à vegetação e também os diferentes tipos de solo presentes na imagem. Para as amostras da vegetação (cana de açúcar) e amostras de solo, foram coletadas dez amostras. Por apresentar diferentes tonalidades, o solo foi dividido em duas classes (uma mais clara e outra mais escura).

A aplicação da classificação não supervisionada foi desenvolvida no *software* Spring. O Spring é um Sistema de Informações Geográficas (SIG) com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta de banco de dados espaciais. Foi inicialmente realizada a transformação RGB da imagem tiff para IHS. Com a banda H (*Hue*) resultante da transformação foi aplicada a classificação não supervisionada usando o método de K-Médias, que

gerou o produto RASTER utilizado para a obtenção dos resultados prévios deste estudo.

A parte final consiste na utilização de técnicas de geoprocessamento para a obtenção dos produtos finais. O produto RASTER obtido após a classificação não supervisionada é transformado em um produto vetorial. O procedimento de extração de falhas é resultado da diferença entre o produto vetorial obtido pelo RASTER com a vetorização das linhas de plantio de cana de açúcar. As metodologias utilizadas estão descritas a seguir.

#### **4.1.1 Localização da área de estudo**

Esta pesquisa foi realizada na Zona Rural do município de Paudalho, estado de Pernambuco, localizado na Zona da Mata Norte, fazendo limite ao Norte com Tracunhaém, ao Sul com Camaragibe, São Lourenço da Mata, Chã de Alegria e Glória de Goitá a Leste com Abreu e Lima e Paulista e a Oeste com Lagoa de Itaenga e Carpina (Figura 5).

O município se estende por 277,51 km<sup>2</sup>, inserida na bacia hidrográfica do rio Ipojuca e uma população total de 51374 habitantes de acordo com o último censo tendo uma densidade demográfica de 185,1 habitantes por km<sup>2</sup>.

A principal atividade econômica do município é composta pela plantação de cana de açúcar. A área selecionada para os estudos apresenta em quase todo seu território as atividades de cultivo de cana de açúcar e uma pequena porção de Mata Atlântica que representa menos de 5% da área selecionada.

Figura 5 - Localização do município de Paudalho - PE



Fonte: O Autor (2018)

Para a tomada das fotografias foi utilizada a câmera SONY Modelo alfa-6000 com distância focal fixa de 16 mm. Os dados foram coletados no dia 26 de junho de 2016, antes da vigência da nova resolução da ANAC (2017) que disciplina o uso de RPAs.

A área compreendida do voo foi de aproximadamente 130 ha a uma altitude média de 220 m que geraram 184 imagens com um GSD (*Ground Sample Distance*) médio de 5 cm.

Na Aerofotogrametria e Sensoriamento Remoto, o GSD é uma das variáveis mais importantes e é a primeira que deverá ser definida, ela indica a resolução espacial do mapeamento, ou seja, o nível de detalhamento permitido.

A escolha do GSD influencia diretamente na nitidez do mapeamento e na sua capacidade de discretização de alvos e objetos a serem representados,

considerando que para aumentar o nível de detalhamento o voo deve ser mais baixo, consumindo mais recursos, principalmente tempo de voo, bateria, tempo de processamento e armazenamento de dados.

Esses parâmetros apresentados são determinados ou adotados nas etapas de planejamento de voo e do apoio terrestre que são descritas na sequência.

#### **4.1.2 Planejamento do voo**

A etapa de planejamento de voo foi crucial para a obtenção dos dados desejados. nela se definiu os parâmetros que foram utilizados durante o voo e que, ao final, tiveram grande influência na qualidade dos dados obtidos em campo.

Para coleta de dados por RPAs não se aplicam, na totalidade, os conceitos utilizados em projetos aerofotogramétricos analógicos e digitais, pois os dados e as formas de aquisição têm naturezas diferentes.

Para obter bons resultados ao fim do processo é fundamental garantir uma alta sobreposição lateral e longitudinal das imagens para que a nuvem de pontos a ser gerada para elaboração dos modelos tenha um maior adensamento de pontos.

Um território com relevo suave, com poucos acidentes geográficos, requer uma sobreposição longitudinal e lateral das fotografias, superior a 50%. Para áreas com maiores variações de altimetria é necessário adotar sobreposições superiores a 80% e 60%, longitudinal e lateral respectivamente.

A área de estudo desta pesquisa apresenta altas diferenças de cotas, desta forma, para se obter uma melhor qualidade das informações planialtimétricas, foi adotada a sobreposição longitudinal de 80% e a sobreposição lateral de 60%.

#### **4.1.3 Apoio terrestre**

Mesmo já estando em vigor a Norma da Especificação Técnica para Controle de Qualidade de Dados Geoespaciais (EB80-N-72.004), 1ª Edição, de 10 de fevereiro de 2016 (MD, 2016), não foi considerado as especificações contidas nessa norma, por não ser objeto desta pesquisa a análise da qualidade posicional dos dados. A

imagem utilizada na pesquisa não passou por análise de qualidade do georreferenciamento, nem da ortorretificação.

Como apoio de campo para os ajustes espaciais das imagens, foram utilizados 4 (quatro) pontos de controle coletados em campo (Figura 6) que, mesmo não garantindo o controle posicional e não atendendo à EB80-N-72.004, não comprometeu os resultados da pesquisa que se propõem ao estabelecimento de uma metodologia e não a diagnóstico absoluto da área de estudo.

Figura 6 – Distribuição dos pontos de controle em campo do aerolevanteamento



Fonte: O Autor (2018)

O procedimento para determinação das coordenadas planimétricas dos quatro pontos de controle foi realizado pelo método de Posicionamento por Ponto Preciso com apoio de GNSS (*Global Navigation Satellite System*). A coordenadas altimétricas desses pontos foram determinados com o uso do MapGeo (IBGE). O

MAPGEO é um Modelo Digital obtido a partir de levantamentos geodésicos, que descreve a variação entre a superfície elipsoidal e a superfície do geóide.

Os pontos de controle selecionados para ajustes espaciais das imagens devem ser perfeitamente fotoidentificáveis e/ou previamente marcados em campo (Figura 7).

Figura 7 – Materialização dos pontos de controle de campo



Fonte: O Autor (2018)

#### 4.2 PROCESSAMENTO DOS DADOS DE VOO

O processamento dos dados foi executado no programa computacional *Agisoft PhotoScan*.

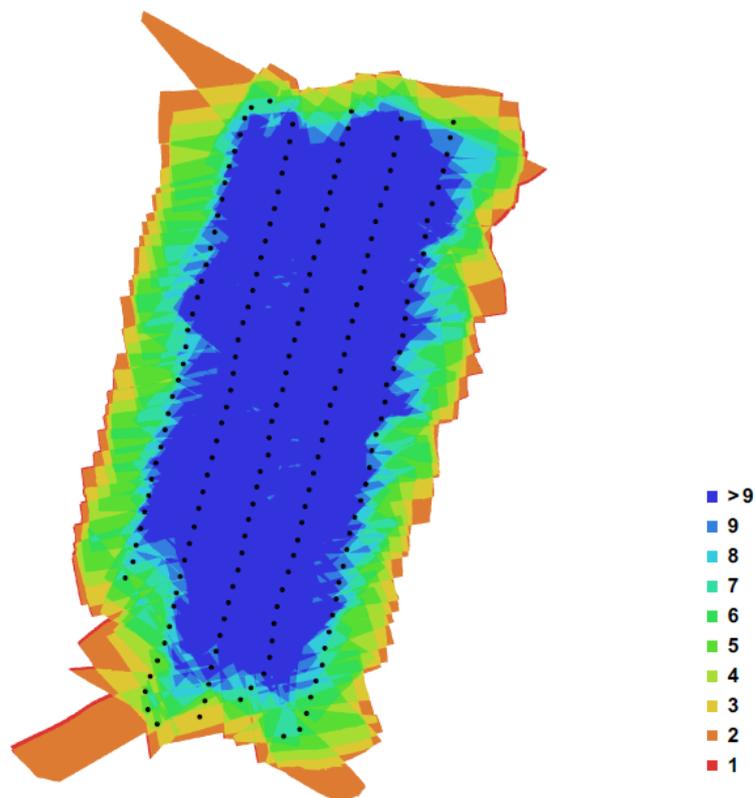
A primeira etapa do processamento consistiu no alinhamento das imagens, no qual os algoritmos implementados no *Agisoft PhotoScan* reconhecem a posição de cada fotografia aérea no momento da tomada. Nessa etapa o *software* calcula as posições do ponto principal e os parâmetros de rotação das imagens.

Em seguida foi verificado a localização dos pontos de controle de campo em um mosaico preliminar e a marcação desses pontos em suas respectivas fotografias. Para isso foram utilizados os alvos previamente materializados com uso de pares de pedras cerâmicas, na cor branca, com dimensões regulares de 20 cm de lado e que são facilmente identificados nas fotografias (Figura 7), esse processo é chamado de identificação dos pontos de controle.

A Figura 8 mostra a distribuição da quantidade de fotografias por áreas e as linhas de voo de voo. Cada ponto representa uma fotografia tomada durante o voo e as cores a quantidade de fotografias sobrepostas em cada posição.

Após a marcação dos pontos de controle de campo no mosaico preliminar, foram atribuídas as coordenadas obtidas no apoio terrestre (GNSS e MapGeo). Mesmo com a adoção de poucos pontos de controle e mesmo com a determinação das altimetrias se dando de forma indireta (MapGeo), após atribuídas as coordenadas aos pontos de controle, o ortomosaico irá apresentar um georreferenciamento compatível com os objetivos da pesquisa.

Figura 8 - Linhas de voo e sobreposição de fotografias



Fonte: O Autor (2018)

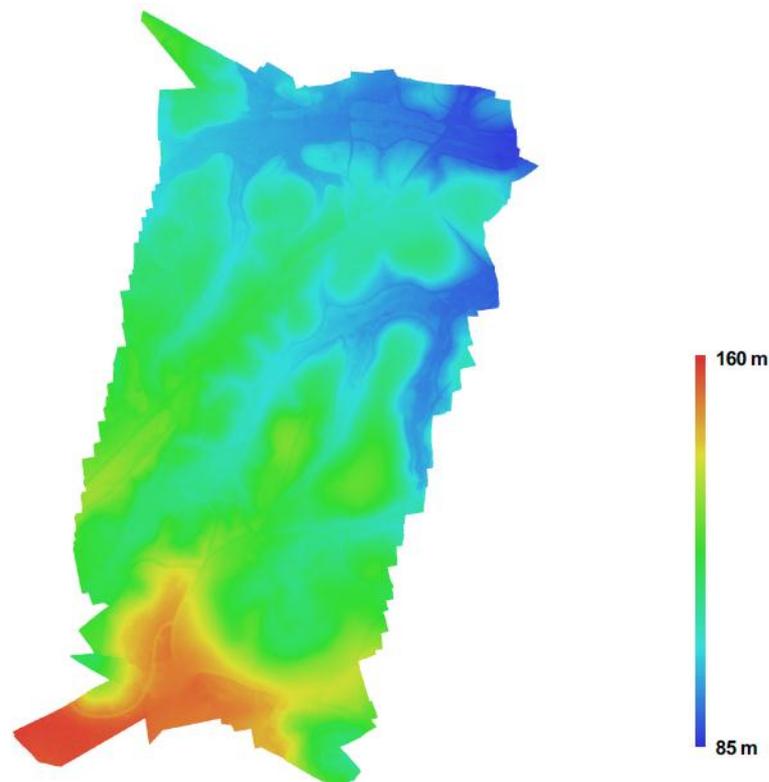
Na etapa seguinte foi realizado o processo de localização de pontos homólogos nas imagens e realizado o processamento tridimensional, tendo como resultado uma nuvem densa de pontos que reproduziu com alta fidelidade a realidade encontrada no terreno.

A partir do ortomosaico construído foi possível exportá-lo em formato RASTER para sequência ao estudo proposto. De acordo com Silva *et al.* (2015), após o processamento tridimensional, é gerada uma nuvem de pontos que representa a superfície da área por meio de um conjunto de pontos de coordenadas tridimensionais, representando um Modelo Digital de Superfície (MDS) incluindo, além do terreno, os objetos a ele superpostos (vegetação, edificações, etc.). O MDT (Modelo Digital de Terreno) e o MDS (Modelo Digital de Superfície) consistem na representação do terreno através de modelos em 3D. Este tipo de modelagem é possível quando se possui uma base em 2D e a altimetria desta mesma localidade.

Após gerado o MDS é realizado um processo de filtragem que pode ser feito manualmente através da visão estereoscópica ou através de algoritmos de filtragem. Neste processo de filtragem os objetos acima do solo são removidos e a superfície é reconstruída através de um processo de interpolação dos pontos.

Para extrair o MDT, quando os dados altimétricos representam apenas a superfície do terreno, foi realizada a filtragem e classificação automática da nuvem de pontos gerada pela tecnologia de modelagem da superfície, Figura 9.

Figura 9 - Modelo Digital de Terreno



Fonte: O Autor (2018)

O Modelo Digital de Terreno revelou uma área bastante acidentada, com alturas variando de 85 metros até 160 metros no seu ponto mais alto. A partir do Modelo Digital de Terreno foram geradas as curvas de nível com equidistância de 1 (um) metro. Em seguida foi realizada a suavização dessas curvas a partir de uma simplificação de sua geometria, com tolerância de 50 centímetros e a eliminação de ruídos com apenas uma iteração entre os procedimentos.

### 4.3 ANÁLISE DAS FALHAS

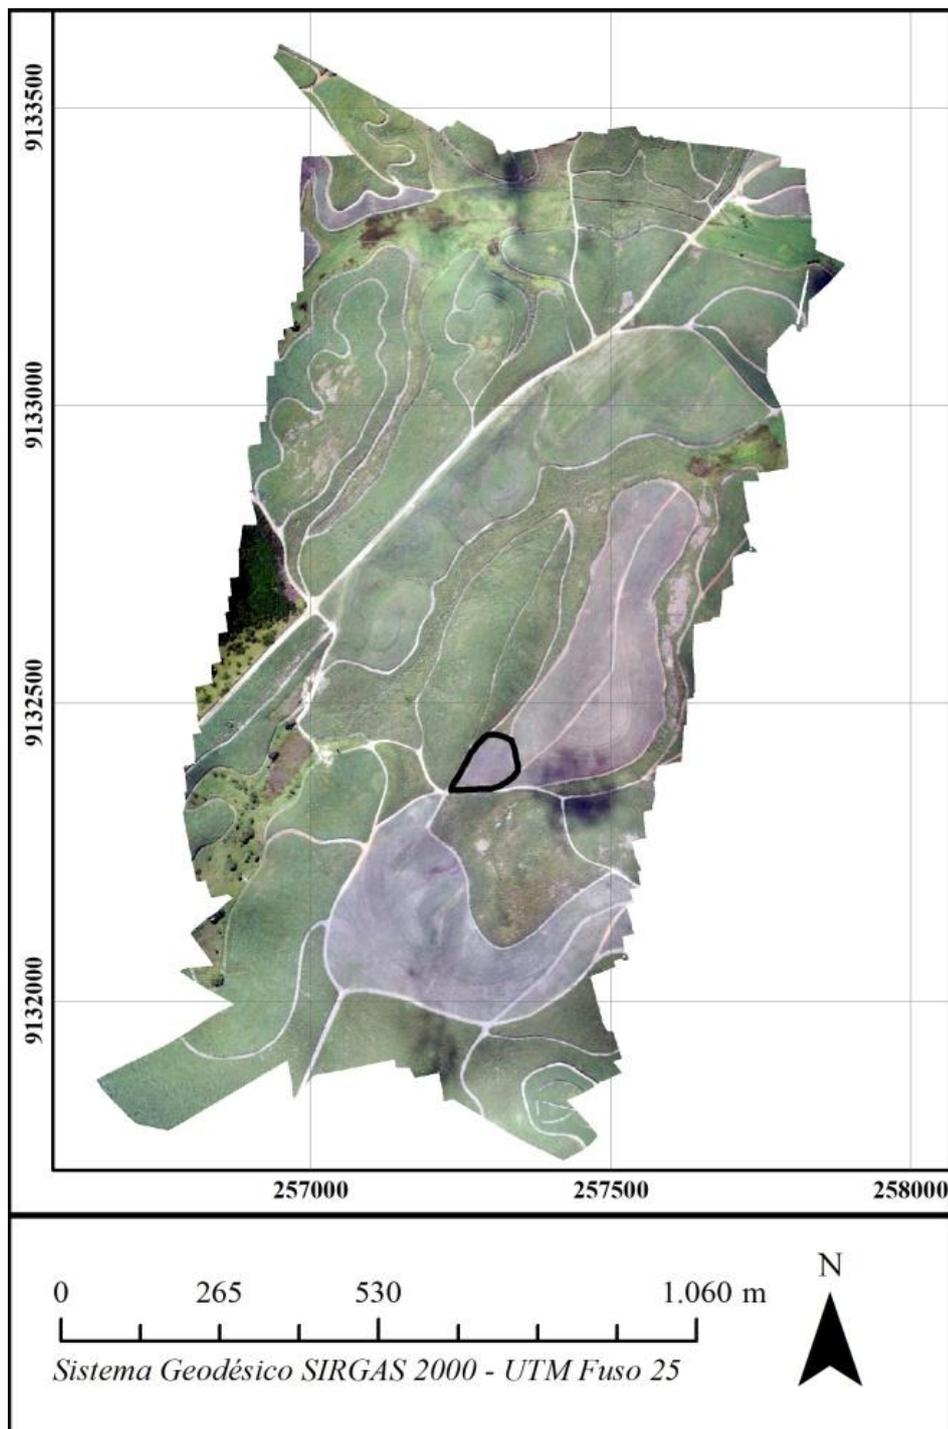
Nesta seção iremos abordar as etapas inerentes ao processo de extração das falhas através da análise topológica dos vetores produzidos com os dados da base cartográfica gerada pelo aerolevanteamento por RPA.

#### 4.3.1 Seleção e preparação de Amostra

Com a finalização dos produtos e a obtenção do ortomosaico, prosseguiu-se com as etapas seguintes da pesquisa, sendo decidido a seleção de uma amostra uniforme na área de estudo para a obtenção dos resultados iniciais e sequência dos trabalhos. Essa amostra consistiu de um pequeno talhão, localizado no centro da área, como mostrado na Figura 10 e Figura 11.

Um talhão é a unidade mínima de cultivo de uma propriedade que é construído com base em relevo e planejamento de mecanização. Em cana de açúcar os talhões são criados respeitando as curvas de nível e com comprimento ideal para preencher a capacidade de um transbordo.

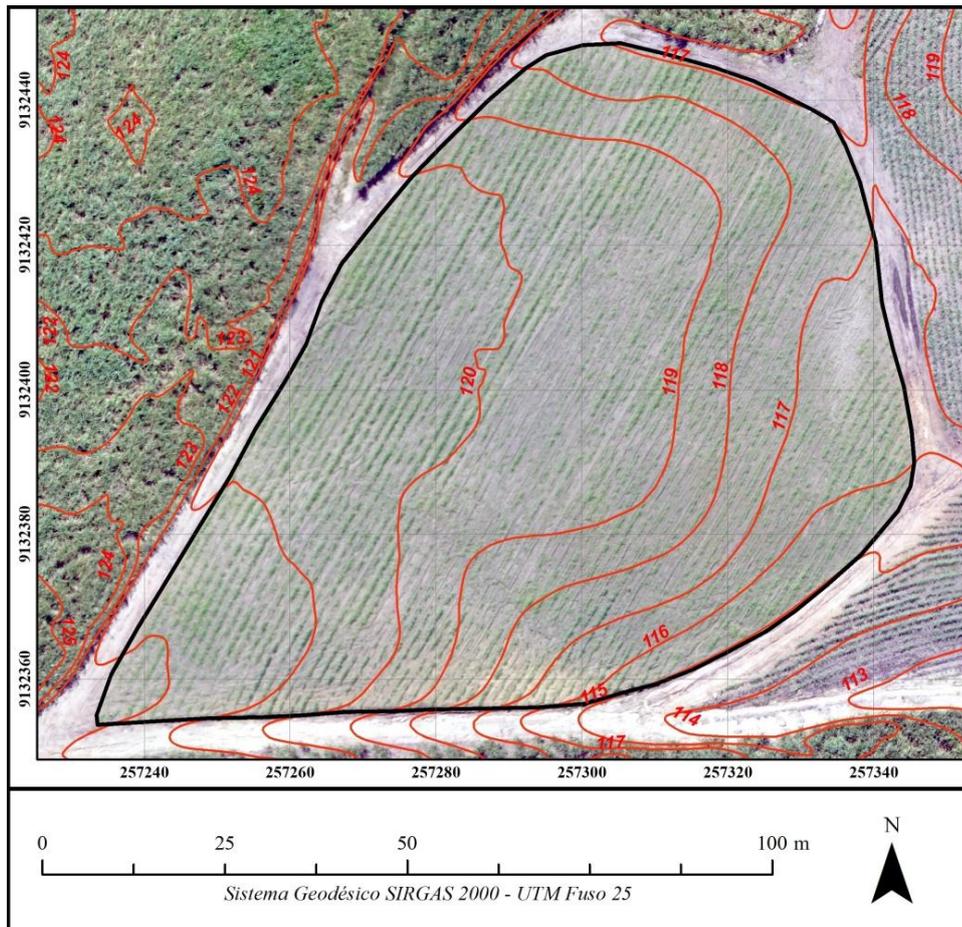
Figura 10 - Identificação da amostra selecionada para a pesquisa



Fonte: O Autor (2018)

Nesta pesquisa as demais imagens referentes ao talhão de estudo não terão suas coordenadas impressas, para deixar uma melhor visualização das figuras.

Figura 11 - Amostra com as curvas de nível



Fonte: O Autor (2018)

Com a definição da amostra foi possível notar que a mesma possui elevadas falhas em sua composição, compreendendo as camadas de solo exposto. O talhão escolhido possui uma área de cerca de 0,7 ha, dentre os quais pode-se observar uma variação de 6 m entre as curvas de nível delimitadas pelo talhão.

Para iniciar o procedimento de análise das falhas, as linhas de plantio foram vetorizadas manualmente, uma a uma, (Figura 12) de forma que fosse possível a quantificação dos dados para serem tratados.

A vetorização das linhas (Figura 13) é uma etapa bastante importante na análise, pois é a partir delas que se obtém o comprimento total do que foi cultivado e de onde se dará a análise das falhas de forma estatística.

As linhas de plantio representam a totalização do que foi plantado em termos de distâncias. Esta etapa recebe como dado de entrada uma imagem contendo a

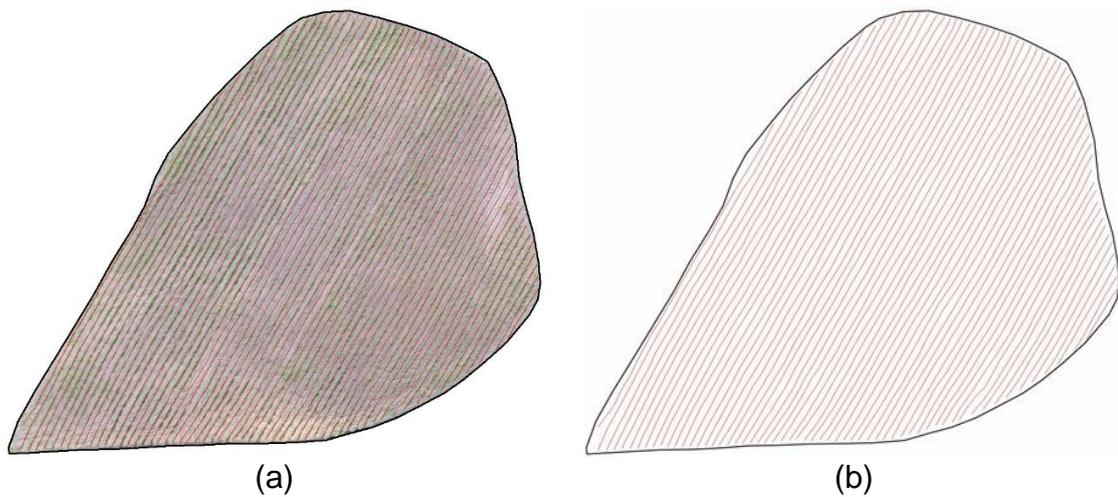
plantação de cana de açúcar e como resultado de saída as linhas de cana de açúcar que a compõem. A grande dificuldade desta etapa é a falta de padrão das linhas e do tamanho das plantas (STOLF *et al.*, 2016).

Figura 12 - Detalhe da vetorização das linhas de plantio de cana de açúcar



Fonte: O Autor (2018)

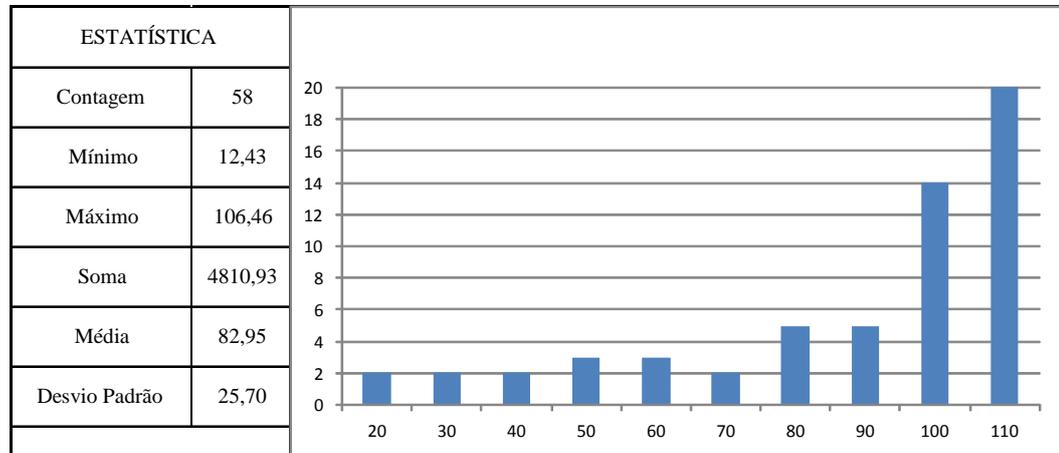
Figura 13 – Linhas de plantio vetorizadas a partir do ortomosaico.



Fonte: O Autor (2018)

A Figura 14 mostra as estatísticas equivalentes da vetorização das linhas de plantio no talhão de estudo em função do tamanho individual de cada linha vetorizada.

Figura 14 – Distribuição de frequências e estatísticas das linhas de plantio.



Fonte: O Autor (2018)

A contagem indica quantas linhas foram vetorizadas no talhão. O valor mínimo indica o menor tamanho vetorizado de linha e o valor máximo o maior tamanho vetorizado de linha. A soma indica o comprimento total de todas as linhas vetorizadas e é o principal indicador analisado, pois os comprimentos das falhas que foram calculados nesta pesquisa estão em função do tamanho total das linhas vetorizadas. A média indica a média aritmética dos tamanhos das linhas vetorizadas e por fim temos o desvio padrão das linhas vetorizadas.

#### 4.3.2 Transformação RGB - IHS

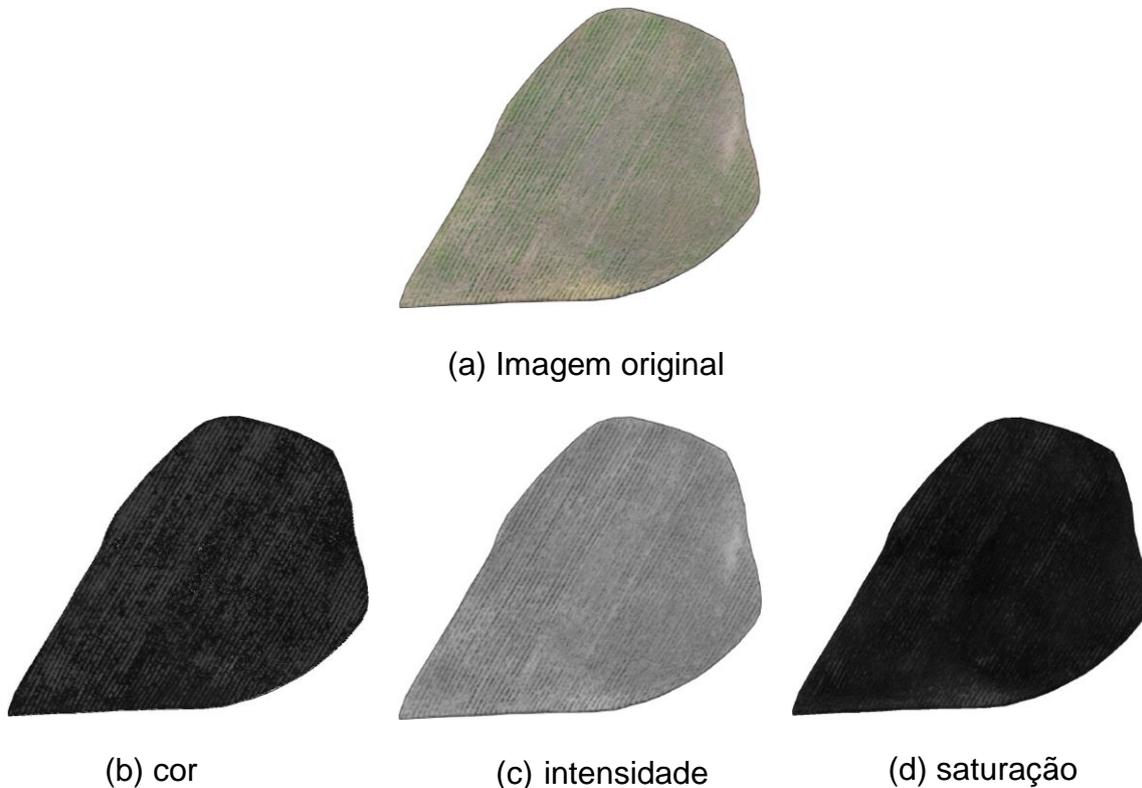
Após a vetorização manual das linhas de plantio finalizadas, prosseguiu-se com a etapa de Processamento Digital das Imagens (PDI). Inicialmente foi realizada a transformação RGB – IHS.

A transformação entre estes modelos de cores é uma técnica de PDI utilizada em muitas aplicações, que proporcionou um resultado visual bastante interessante. O princípio básico neste tipo de operação é que a imagem intensidade, do sistema IHS, é muito similar a imagem pancromática da mesma área, podendo substituí-la

sem alterar as características espectrais, com a vantagem de oferecer maior grau de detalhe espaciais.

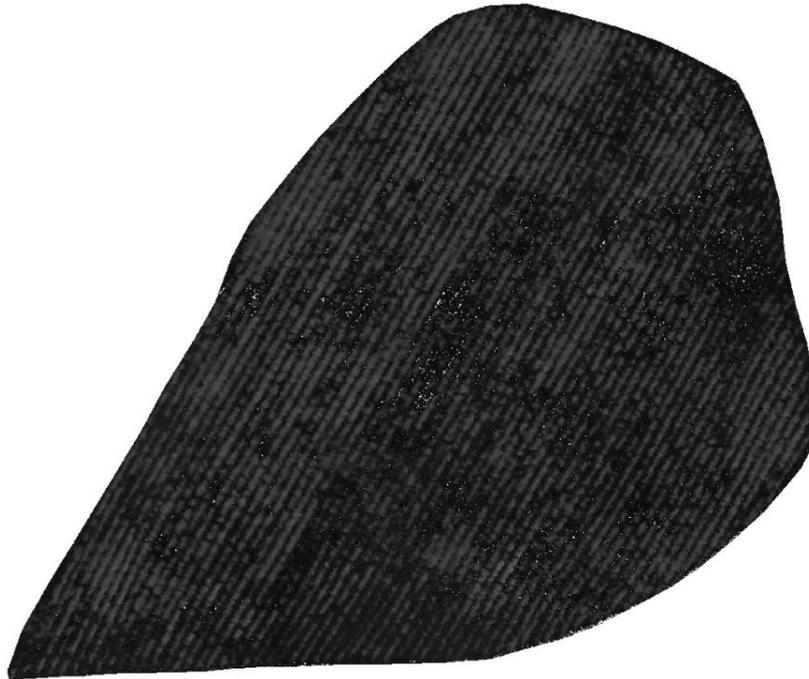
Na Figura 15 é possível notar as partes mais claras como sendo a vegetação (camada de interesse) e algumas pequenas áreas em branco. Essas áreas em branco são representadas como sendo vermelho, da mesma forma que as partes mais escuras também representam o vermelho que neste caso significam solo exposto. Quando se transforma a imagem RGB em IHS, tem-se um destaque das falhas da vegetação na banda resultante H (*Hue*), Figura 16, e esse resultado pode ser usado na classificação não supervisionada k-medias.

Figura 15 - Imagem original (a) e as Bandas Cor (b), Intensidade (c) e Saturação (d)



Fonte: O Autor (2018)

Figura 16 - Banda H (cor) resultante da transformação RGB – IHS



Fonte: O Autor (2018)

### 4.3.3 Classificação não supervisionada

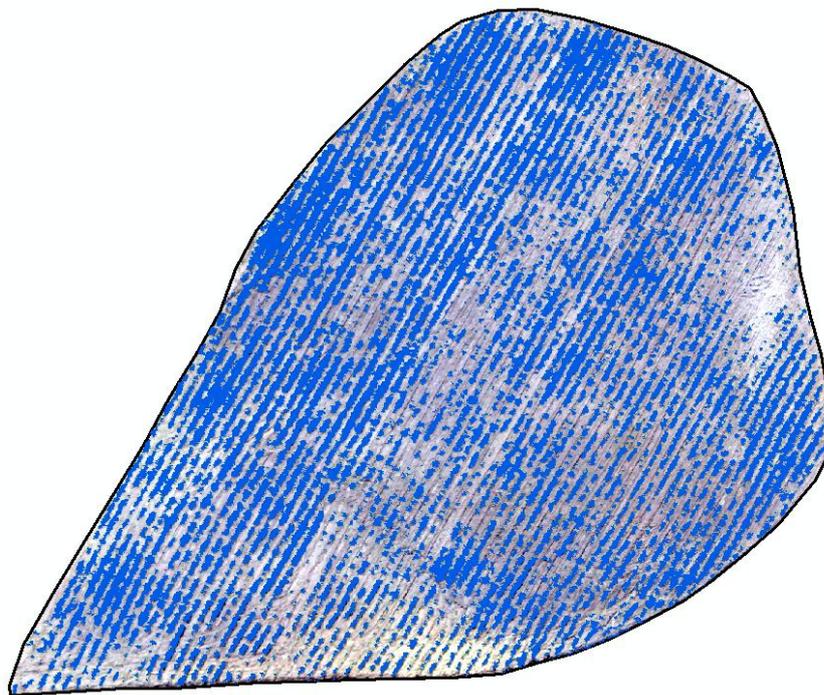
Os procedimentos de classificação visam substituir a análise ou a interpretação visual da imagem por técnicas quantitativas que identificam automaticamente os padrões de cobertura terrestre existente em uma cena. A classificação não supervisionada é a técnica pela qual os pixels de uma imagem são atribuídos às classes espectrais sem que haja qualquer tipo de conhecimento sobre a existência ou nome dessas classes. Esses métodos examinam os pixels desconhecidos de uma imagem e os incorporam dentro de um conjunto de classes definidas em função dos agrupamentos naturais dos níveis de cinza dos pixels da imagem.

É importante ressaltar que a utilização de uma classificação não supervisionada visa coletar os resultados da pesquisa com o mínimo de variáveis possíveis para posteriormente haver uma comparação de resultados com uma classificação supervisionada.

Foi utilizado o algoritmo K-Médias para a classificação das feições (Figura 17). O algoritmo K-Médias é um procedimento iterativo que busca minimizar a variância interna dos agrupamentos que são formados durante o processo de particionamento dos dados.

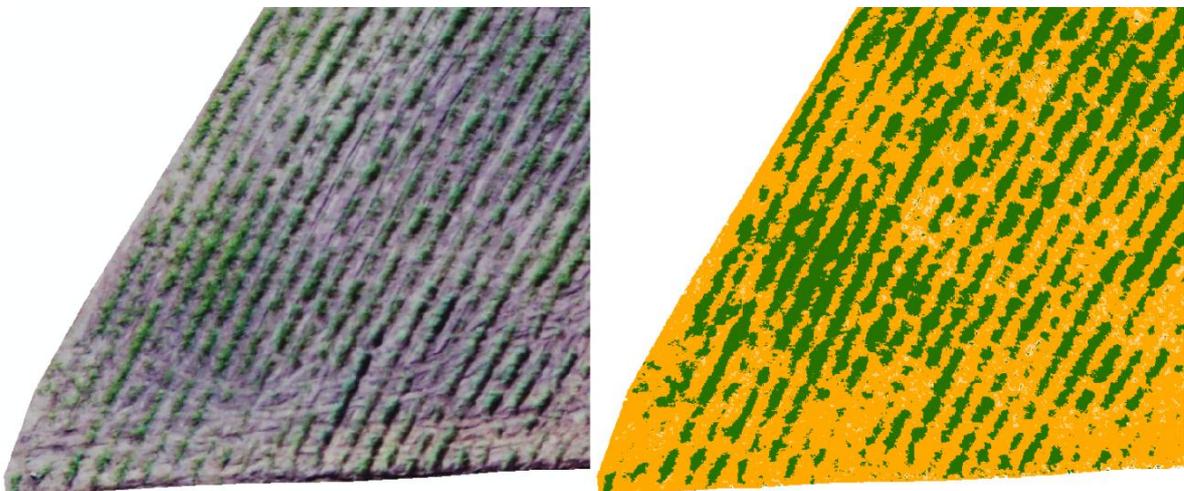
Para os testes iniciais, foram comparados os resultados com três e quatro classes cada uma com dez iterações (Figura 18). Os resultados foram muito similares havendo diferenças basicamente nas sombras formadas pela cana de açúcar e a própria cana de açúcar. Como neste caso a sombra pertence a vegetação propriamente dita, ficou definido o uso de três classes com um total de 10 iterações, levando em consideração a simplicidade dos objetos alvos encontrados na cena.

Figura 17 - Vegetação extraída do algoritmo K-Médias



Fonte: O Autor (2018)

Figura 18 - Comparativo do resultado da classificação não supervisionada



Fonte: O Autor (2018)

#### 4.3.4 Classificação supervisionada

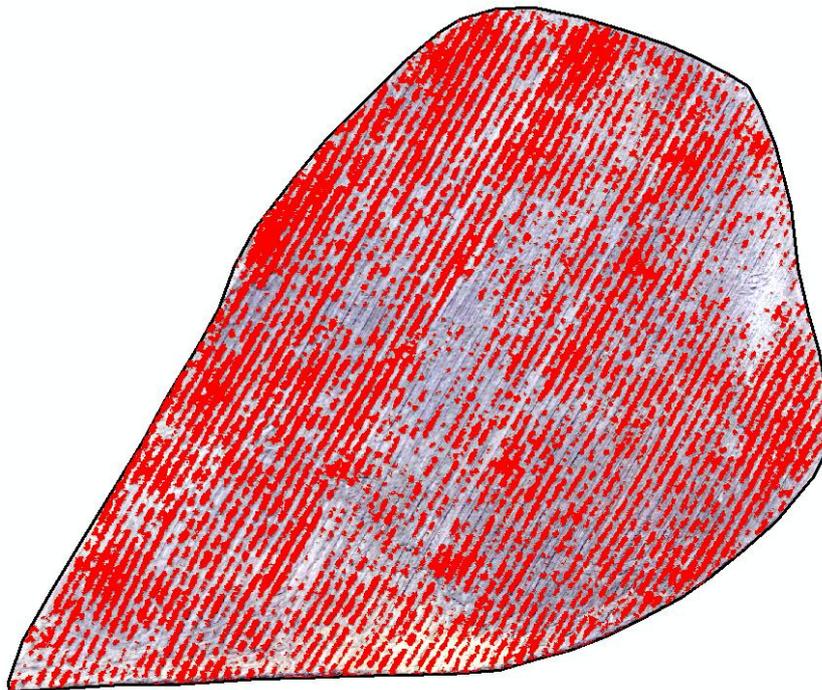
A classificação supervisionada de imagens orbitais é um método amplamente utilizado em estudos de mapeamento e avaliação das mudanças ocorridas no uso e ocupação do solo.

Entre os métodos de classificação supervisionada de imagens, o algoritmo da máxima verossimilhança (Maxver), Figura 19, está entre uma das metodologias mais aplicadas a estudos de caracterização, mensuração e monitoramento de áreas florestais e agrícolas. São utilizadas amostras previamente selecionadas para o treinamento do classificador. Esta classificação considera a ponderação das distâncias entre médias dos níveis de cinza das classes.

Para o talhão de estudo, foram discretizados os elementos presentes na área, compreendendo de solo exposto e vegetação (cana de açúcar), Figura 20. Foram definidas 3 classes para a extração das informações: Classe 1: Solo exposto mais claro, Classe 2: Solo exposto mais escuro e Classe 3: Vegetação (cana de açúcar).

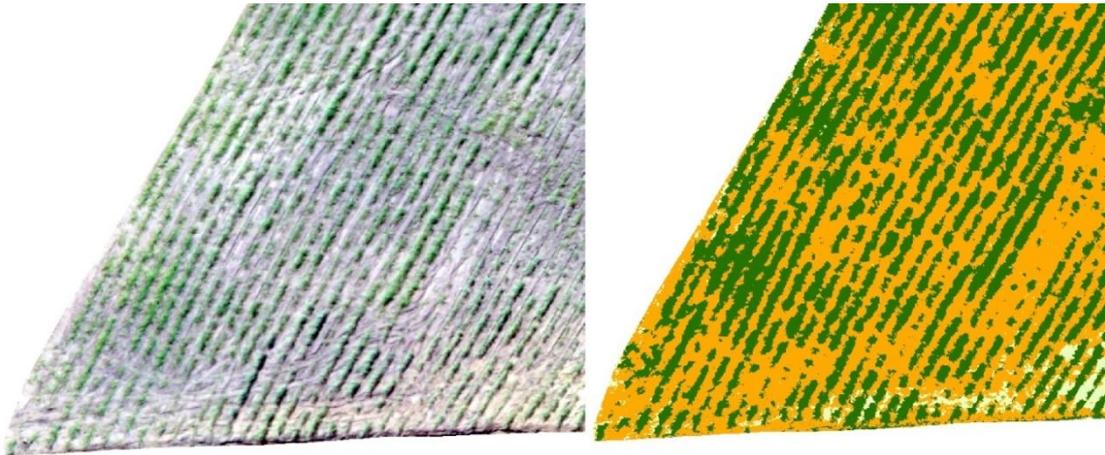
Para cada classe foram coletadas dez amostras de pixels no terreno. Para a classe da vegetação, regiões com sombras foram consideradas como elementos de vegetação, já que tais sombras aparecem ao bordo das linhas de plantio.

Figura 19 - Vegetação extraída do algoritmo Maxver



Fonte: O Autor (2018)

Figura 20 - Comparativo do resultado da classificação supervisionada



Fonte: O Autor (2018)

#### 4.3.5 Procedimento de extração de feições

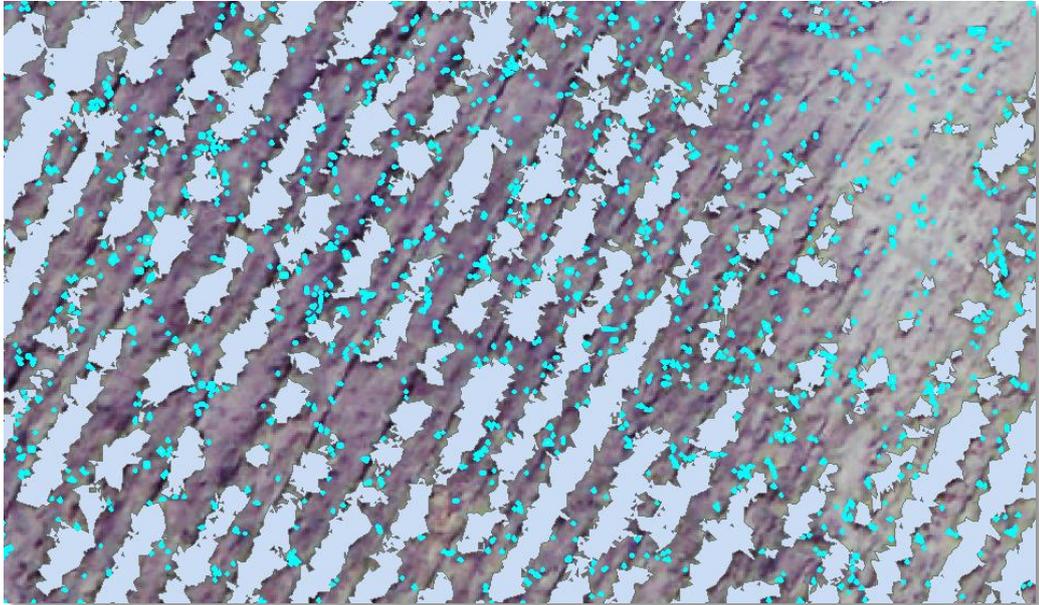
Como demonstrado nas sessões anteriores, pelo resultado da classificação não supervisionada e supervisionada, foi possível extrair a informação da vegetação presente na área estudada. Os produtos RASTER obtidos pelas classificações foram transformados em produtos vetoriais. Nesta etapa é realizada a transformação RASTER para polígono que está disponível em plataforma GIS. Esta ferramenta produz os polígonos resultantes da classificação e ao mesmo tempo permite realizar uma simplificação de sua geometria. Esta simplificação reduz a complexidade dos polígonos, sendo definida apenas para efeitos de simplificação do resultado obtido.

Com a transformação concluída, a próxima etapa foi isolar os polígonos de interesse, já que o produto resultante contém toda a informação do RASTER inicial. Com a tabela de atributos é possível extrair os polígonos pertencentes à classe de vegetação, bem como calcular as áreas de cada polígono.

A extração das feições da vegetação neste procedimento foi simples, obtendo a exportação através de ferramentas de geoprocessamento, transformando ao final o RASTER obtido em polígonos. Com esses polígonos simplificados, foi possível extrair apenas os polígonos que representam a vegetação. Os polígonos gerados possuem muitas partículas que não interessam para os procedimentos. Essas partículas possuem áreas muito pequenas que podem ser visualizadas através da

tabela de atributos o que gerou ruídos resultantes das classificações. Neste estudo foram desconsideradas áreas menores que 0,025 m<sup>2</sup> (Figura 21).

Figura 21 - Exclusão dos polígonos de vegetação extraídos através da imagem raster

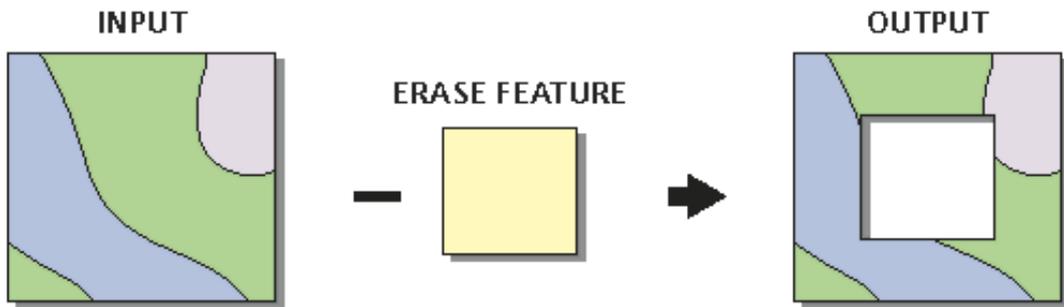


Fonte: O Autor (2018)

O produto final desta parte do geoprocessamento (Figura 25) é a cana de açúcar que foi considerada como plantada após 90 dias do início do plantio. Existe um efeito comparativo entre a imagem original sobreposta aos polígonos extraídos da classificação para verificar visualmente a qualidade final obtida pelos produtos produzidos.

Com a separação dos polígonos, foi possível extrair a partir das ferramentas de geoprocessamento (Figura 22), a diferença entre as linhas de plantio traçadas inicialmente com os polígonos gerados após as classificações, exibindo como resultado as falhas de plantação. O traçado final foi obtido após a aplicação de funções disponíveis em ambiente GIS. Foi aplicado o corte das linhas de plantio usando como máscara de recorte os polígonos obtidos pelas classificações. Com as linhas resultantes, foram calculados o comprimento de cada uma.

Figura 22 – Analogia do geoprocessamento utilizado no cálculo das falhas

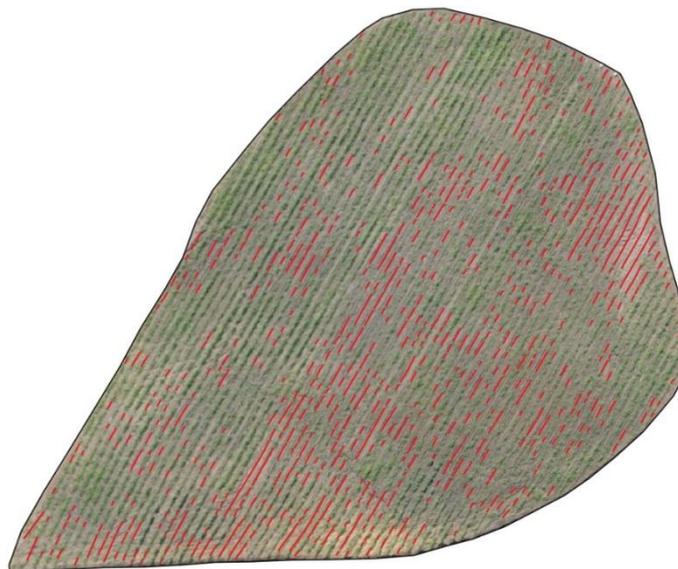


Fonte: ESRI

A Figura 22 representa de forma esquemática o procedimento utilizado para a determinação das falhas. O *input* indica a feição de interesse, no caso, as linhas de plantio vetorizadas. A camada máscara (*Erase Feature*) são os polígonos extraídos das classificações utilizadas neste estudo. *Output* é a resultante do que foi extraído entre as linhas de plantio vetorizadas e os polígonos, sendo, portanto as falhas resultantes, já que estas são a representação do que sobrou das linhas de plantio vetorizadas.

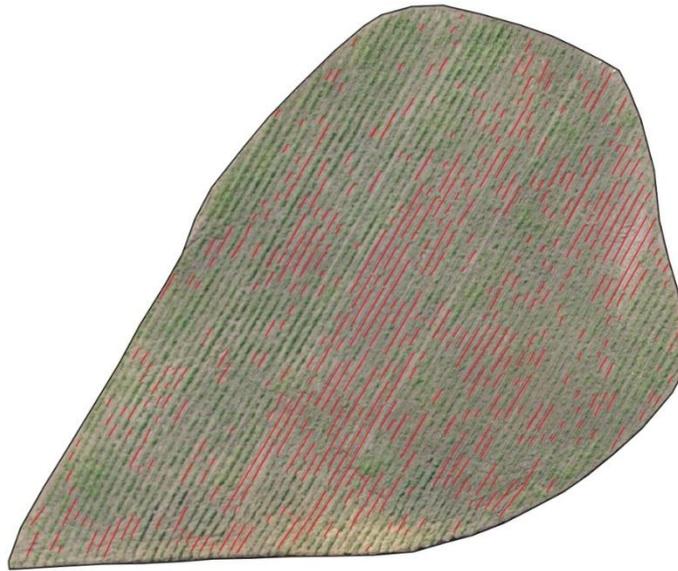
O produto final de todo este procedimento são as falhas no plantio de cana de açúcar. A Figura 23 e Figura 24 mostram respectivamente a área total com as falhas de cada algoritmo utilizado e o detalhamento como o resultado final. A Figura 25 mostra em detalhes o resultado dos vetores resultantes que representam as falhas.

Figura 23 - Falhas resultantes do plantio usando algoritmo K-Médias



Fonte: O Autor (2018)

Figura 24 - Falhas resultantes do plantio usando algoritmo Maxver



Fonte: O Autor (2018)

Figura 25 - Detalhe de um dos resultados do geoprocessamento das falhas na cana de açúcar



Fonte: O Autor (2018)

A etapa seguinte compreendeu da análise quantitativa das falhas em relação a cada classificação usada na pesquisa. A Tabela 1, a seguir, mostra a quantidade de vezes que a falha é contabilizada. Foi considerada para a montagem das tabelas

abaixo o limite de 2 metros para o tamanho máximo da falha, pois aqui procuramos mostrar a parte significativa em relação ao quantitativo. Embora uma falha de comprimento maior que 2 metros tenham representatividade visual, no caso das Tabela 1 e Tabela 2, a quantidade de vezes que um tamanho de falha maior que 2 metros se repetam, acaba não sendo tão representativa para a montagem dos gráficos que virão em seguida.

Tabela 1 - Quantitativo das falhas por tamanho.

Comprimento (cm)	K-Médias			Supervisionada		
	Quantidade	Representatividade (m)	%	Quantidade	Representatividade (m)	%
10	1909	190,90	3,97%	1585	158,50	3,29%
20	1504	300,80	6,25%	1266	253,20	5,26%
30	1214	364,20	7,57%	1050	315,00	6,55%
40	993	397,20	8,26%	876	350,40	7,28%
50	811	405,50	8,43%	742	371,00	7,71%
60	683	409,80	8,52%	622	373,20	7,76%
70	570	399,00	8,29%	520	364,00	7,57%
80	479	383,20	7,97%	449	359,20	7,47%
90	408	367,20	7,63%	387	348,30	7,24%
100	358	358,00	7,44%	322	322,00	6,69%
110	310	341,00	7,09%	281	309,10	6,42%
120	273	327,60	6,81%	255	306,00	6,36%
130	234	304,20	6,32%	229	297,70	6,19%
140	207	289,80	6,02%	208	291,20	6,05%
150	188	282,00	5,86%	189	283,50	5,89%
160	156	249,60	5,19%	165	264,00	5,49%
170	140	238,00	4,95%	149	253,30	5,27%
180	129	232,20	4,83%	137	246,60	5,13%
190	116	220,40	4,58%	124	235,60	4,90%
200	109	218,00	4,53%	115	230,00	4,78%

Fonte: O Autor (2018)

A Tabela 1 mostra a quantidade de vezes que um determinado tamanho de falha acontece na região estudada em relação a cada classificação. A representatividade equivale ao tamanho total de falhas para cada comprimento e o percentual ao tamanho total das linhas vetorizadas as quais foram calculadas anteriormente. Enquanto a Tabela 2 mostra a diferença entre os quantitativos dos comprimentos das falhas e sua representatividade.

Tabela 2 - Diferença entre os classificadores.

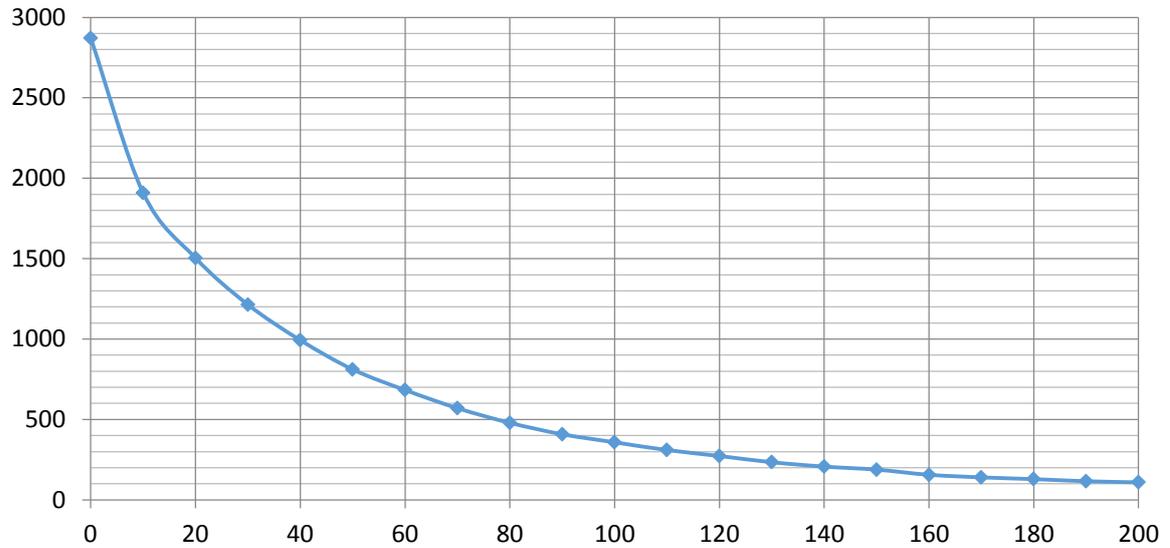
Comprimento (cm)	K-Médias	Supervisionada	Diferenças	Diferenças por tamanho (m)	%
	Quantidades				
10	1909	1585	324	32,40	0,67%
20	1504	1266	238	47,60	0,99%
30	1214	1050	164	49,20	1,02%
40	993	876	117	46,80	0,97%
50	811	742	69	34,50	0,72%
60	683	622	61	36,60	0,76%
70	570	520	50	35,00	0,73%
80	479	449	30	24,00	0,50%
90	408	387	21	18,90	0,39%
100	358	322	36	36,00	0,75%
110	310	281	29	31,90	0,66%
120	273	255	18	21,60	0,45%
130	234	229	5	6,50	0,14%
140	207	208	1	1,40	0,03%
150	188	189	1	1,50	0,03%
160	156	165	9	14,40	0,30%
170	140	149	9	15,30	0,32%
180	129	137	8	14,40	0,30%
190	116	124	8	15,20	0,32%
200	109	115	6	12,00	0,25%

Fonte: O Autor (2018)

A Tabela 2 mostra que na medida em que o tamanho da falha vai aumentando, a diferença entre os classificadores diminui, implicando que, a ocorrência de falhas com tamanhos maiores é menos expressiva quantitativamente que as falhas de tamanhos menores. Como estudado em sessões anteriores nesta pesquisa, a definição de que o tamanho de falha a ser considerado seja de 50 cm confere em bons resultados para os dois classificadores aqui utilizados.

Para visualizarmos os números apresentados nas tabelas anteriores, foram feitos os gráficos do quantitativo das falhas e sua comparação. Os gráficos a seguir mostram o comportamento das falhas em relação a quantidade de vezes em que a mesma é contabilizada.

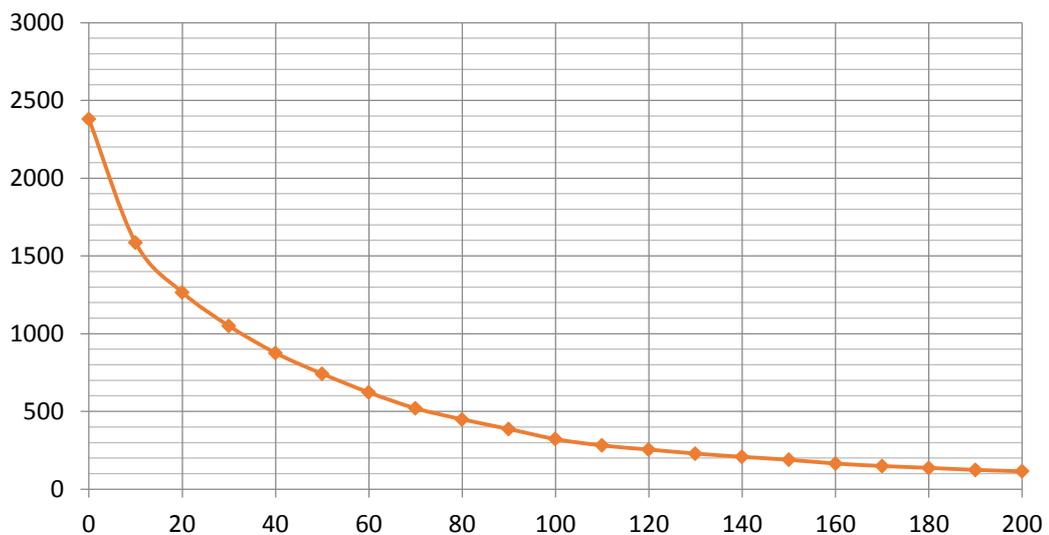
Figura 26 - Gráfico da quantidade de falhas no algoritmo K-Médias



Fonte: O Autor (2018)

Para o gráfico de K-Médias (Figura 26), observou-se uma grande quantidade de unidades de falhas menores que 10 cm. Esses tamanhos foram considerados como ruídos e não constaram nas tabelas anteriores no qual partiu-se de tamanhos maiores que 10 cm. É justamente nesses tamanhos que a curva tem a queda mais acentuada.

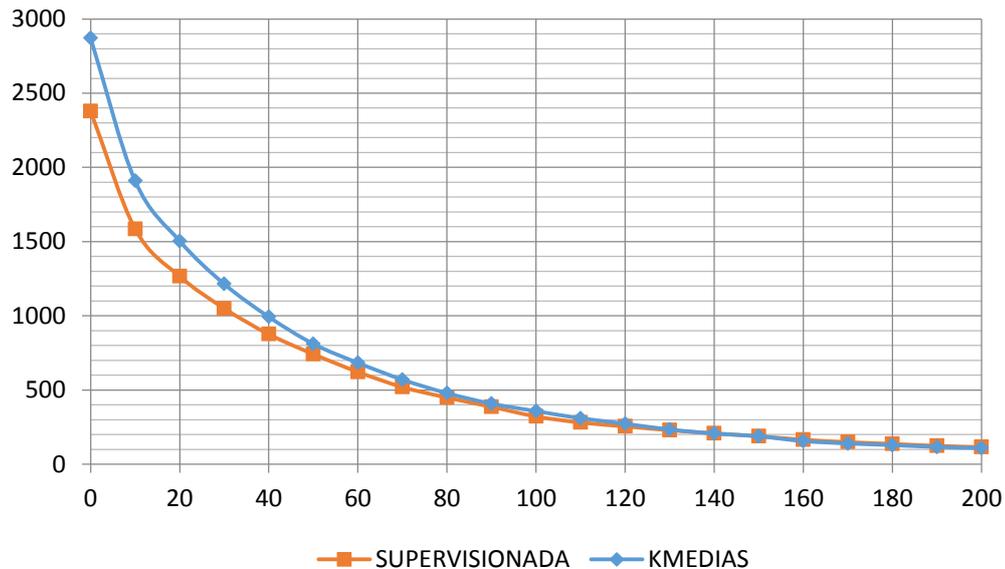
Figura 27 - Gráfico da quantidade de falhas no algoritmo Maxver



Fonte: O Autor (2018)

Para o algoritmo Maxver (Figura 27), a quantidade de ruídos (tamanhos menores que 10 cm) foi bem menor, o padrão da curva apresentou maior suavização à medida que os tamanhos foram aumentando.

Figura 28 - Gráfico da quantidade e comprimento das falhas para os algoritmos MaxVer e K-Médias



Fonte: O Autor (2018)

Nos gráficos anteriores podemos perceber a questão referentes às falhas maiores que 2 m, cujos dados são pouco representativos. As tendências das curvas (Figura 28) foram muito parecidas à medida que o comprimento aumentou. Na Tabela 2 que mostrou a diferença entre os classificadores foi bastante percebida pelos gráficos, onde praticamente as duas curvas ficaram iguais.

As diferenças de alturas entre as curvas foram representadas na Tabela 2 pelo campo “Diferenças”. Podemos visualizar que tamanhos maiores que 50 cm (que foram considerados nesta pesquisa como falhas), entre as duas curvas diminuem a medida que o tamanho das falhas aumenta.

## 5 CONCLUSÕES

As bases cartográficas geradas pelos RPAs foram: Ortomosaico, Modelo Digital de Superfície (MDS), Modelo Digital do Terreno (MDT) e Curvas de nível. Os produtos obtidos também podem servir para outros usos e ocupação do solo. Esses dados são, portanto, promissores e de baixo custo de aquisição, aliados à excelente qualidade de dados gerados, altíssima resolução espacial e temporal atreladas ao produto, se comparado com métodos de obtenção de dados cartográficos convencionais. A base de dados servirá para uma gestão inteligente do plantio de forma que possibilite um melhor aproveitamento produtivo da área.

Os métodos de classificação utilizados nesta pesquisa mostraram resultados coerentes entre si e também com a realidade encontrada no campo. A qualidade dos dados resultantes das classificações ficou excelente de acordo com a altíssima resolução espacial do ortomosaico. A análise das classes foi realizada visualmente, pois a alta resolução permitiu constatar a acurácia visual dos vetores extraídos de cada classificação.

De acordo com os resultados obtidos nesta pesquisa, a cobertura linear das linhas de plantio que foram vetorizadas foi de 4811 metros, com uma área de plantio de aproximadamente 0,7 hectares. Na área estudada houve uma grande identificação de falhas que ocorreu em média de 29% considerando as duas classificações da área o que representa uma grande fatia do que foi inicialmente plantado. O tamanho linear médio das falhas foi de 3,09 m, considerando 50 cm como falha.

As técnicas aqui apresentadas são de grande auxílio na obtenção dos resultados que ajudam a determinar estatisticamente resultados mais precisos e de acordo com a realidade em contrapartida das técnicas manuais clássicas.

Os resultados obtidos com o uso dos algoritmos MaxVer e K-Médias, mostrou que o procedimento de extração de falhas no plantio de cana de açúcar é de extrema confiança. Não somente no cultivo de cana de açúcar os procedimentos podem ser aplicados, mas outros cultivos também nos possibilita aplicar as técnicas aqui expostas.

## REFERÊNCIAS

- ANAC – Agência Nacional de Aviação Civil; **Regras sobre drones**. Regulamento Brasileiro de Aviação Civil Especial – RBAC –E n. 94. 2017.
- ANTUNIASSI, U.R.; SALVADOR, A.; **Análise de imagens aéreas para mapeamento de plantas daninhas em sistemas de agricultura de precisão**. In: SIMPÓSIO INTERNACIONAL DE AGRICULTURA DE PRECISÃO, n. 2., 2002, Viçosa. Anais... Viçosa: UFV, 2002.
- CENTENO, J. A. S.; RIBEIRO, S. R. A.; **Um método simplificado de fusão de imagens**. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, 21-26 abril 2007.
- CRÓSTA, A. P.; **Processamento digital de imagens de sensoriamento remoto**, Campinas, SP, UNICAMP, ed. rev., 1993.
- DAINESE, R. C.; **Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não supervisionada e análise visual**. Dissertação de Mestrado - Faculdade de Ciências Agrônômicas da UNESP - Campus de Botucatu. 2001.
- DEBIASI, P.; ECKHARDT, R. R.; CASTOLLDI, G.; MADRUGA, R.; COUTINHO, A.; Fusão de imagens MODIS com NDVI do Landsat para a classificação de áreas de cultivo de soja. In. XIII Simpósio Brasileiro de Sensoriamento Remoto, **Anais** [...] Florianópolis, Brasil, 21-26 abril 2007.
- ERBERT, M.; **Introdução ao sensoriamento remoto**. Master Tesis, Universidade Federal do Rio Grande do Sul. 2001.
- FIGUEIRA, N. M.; VOLOTÃO, C. F. S.; Detecção do contorno de alvos em imagens adquiridas por VANT. **Revista Brasileira de Cartografia**, n. 65/4: 643-650. 2012.
- INPE – Instituto Nacional de Pesquisas Espaciais; **Tutorial SPRING**. São José dos Campos. 2002.
- MEDEIROS, F. A., ALONÇO, A. S., BALESTRA, M. R. G., DIAS, V. O., LANDERHAL Jr. M. L.; **Utilização de um veículo aéreo não-tripulado em atividades de imageamento georreferenciado**. Ciência Rural, Santa Maria, v-38, n.8, p.2375-2378, Nov, 2008.
- MAPA - MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. **Agricultura de precisão – Boletim Técnico**. Brasília, DF, 2011
- MD - MINISTÉRIO DA DEFESA. **Norma da especificação técnica para controle de qualidade de dados geoespaciais – ET-CQDG**. 2016
- MOLIN, J. P.; VEIGA, J. P. S.; **Spatial variability of sugarcane row gaps: measurement and mapping**. Ciências Agrotec, v.40 n.3 Lavras May/June 2016.

NERIS, L. O.; **Um piloto automático para as aeronaves do projeto ARARA**. 102 f. Dissertação (Mestrado em Ciências da Computação) – Universidade de São Paulo, São Carlos. 2001.

RICHARDS, J.A.; **Remote Sensing Digital Image Analysis. Second Edition**. New York: Wiley, 1993.

RIBEIRO, R. J. C.; BAPTISTA, G. M. M.; BIAS, E. S.; Comparação dos métodos de classificação supervisionada de imagem Máxima Verossimilhança e Redes Neurais em ambiente urbano. XIII Simpósio Brasileiro de Sensoriamento Remoto, **Anais [...]**, Florianópolis, Brasil, 21-26 abril, 2007.

SILVA, C. A.; SOUTO, M. V. S.; DUARTE, C. R.; BICHO, C. P.; SABADIA, J. A. B.; Avaliação da acurácia dos ortomosaicos e modelos digitais do terreno gerados pelo MVANT/DNPM. **Revista Brasileira de Cartografia**, n. 67/7: 1479-1495. 2015.

SILVA, D. C. D.; TOONSTRA, G. W. A.; SOUZA, H. L. S.; PEREIRA, T. A. J.; **Qualidade de ortomosaico de imagens de VANT processados com os softwares APS, PIX4D e PHOTOSCAN**. V Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. 2014.

STOLF, R; GARCIA, T. B.; NERIS, L. O.; TRINDADE JUNIOR, O.; REICHARDT, K. **Avaliação de falhas em cana de açúcar segundo o método de Stolf utilizando imagens aéreas de alta precisão obtidas por VANT**. STAB – Março/Abril 2016, v. 34, n. 4.

WATTS, A. C. et al. **Unmanned Aircraft Systems in Remote Sensing and Scientific Research: Classification and Considerations of Use**. **Remote Sensing**, v.4, n. 12, p. 1671-1692. 2012.

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