

Gustavo Rezende Silva

Desenvolvimento de Algoritmo para Definição de Zonas de Manejo através de Imagens Aéreas

Uberlândia - Brasil

21 de fevereiro de 2018

Gustavo Rezende Silva

Desenvolvimento de Algoritmo para Definição de Zonas de Manejo através de Imagens Aéreas

Trabalho de Conclusão de Curso apresentado
à Faculdade de Engenharia Mecânica como
requisito obrigatório para obtenção do grau
de bacharel em Engenharia Mecatrônica

Universidade Federal de Uberlândia
Faculdade de Engenharia Mecânica
Graduação em Engenharia Mecatrônica

Orientador: Prof. Dr. Mauricio Cunha Escarpinati

Uberlândia - Brasil
21 de fevereiro de 2018

Este trabalho é dedicado à toda humanidade, espero que de alguma forma os conhecimentos produzidos neste projeto auxiliem o mundo a se tornar um lugar melhor.

Agradecimentos

Acredito que a vida de uma pessoa pode ser resumida em uma soma de experiências, sendo assim, em minha opinião somente sou quem eu sou através do acúmulo de todas as experiências, sem exceção, que vivenciei ao longo dos meus 23 anos.

Por isso, agradeço a todos que de alguma forma passaram em minha vida e contribuíram para eu me tornar a pessoa que me tornei.

Em especial, à minha mãe Lucita Carvalho Rezende que sempre acreditou em mim e me deu todo apoio que necessitei, à minha irmã Letícia Rezende Silva com seus conselhos e firmeza, à minha avó Jurany Carvalho de Rezende com seu carinho e sabedoria, e ao meu pai Nélio Antônio da Silva com seu apoio e seriedade.

À minha namorada Mariana Vilela Machado, pelo companheirismo, amor e apoio durante meus dois últimos anos de graduação.

Aos meus caros colegas de turma, que compartilharam comigo muitos momentos de alegria e estudos.

Ao Diretório Acadêmico da Engenharia Mecatrônica (DATRON), que me deu a chance de expandir minhas habilidades pessoais, além de permitir que eu conhecesse inúmeras pessoas fantásticas.

À Equipe de Desenvolvimento de Robótica Móvel (EDROM), pela oportunidade de aprendizado que foi essencial para o meu desenvolvimento técnico como Engenheiro.

Ao Laboratório de Planejamento Automático de Manufatura (MAPL), que me permitiu entrar em contato com a pesquisa acadêmica.

Ao Prof. Dr. Mauricio Cunha Escarpinati e ao Prof. Dr. José Jean-Paul Zanlucchi de Souza Tavares pela orientação durante a realização deste trabalho.

À Sensix, pela oportunidade de aprimorar meu lado técnico e profissional, além do fornecimento dos dados necessários para realização deste trabalho.

"Nós escolhemos ir à lua! Nós escolhemos ir para a Lua nesta década e fazer as outras coisas, não porque sejam fáceis, mas porque são difíceis. Porque esse objetivo servirá para organizar e medir o melhor de nossas energias e habilidades, porque esse desafio é aquele que estamos dispostos a aceitar, um que não queremos adiar e um que pretendemos vencer."(John F. Kennedy, 12 de setembro de 1962)

Resumo

O crescimento contínuo da população mundial resulta em uma maior necessidade de produção de alimentos, entretanto a quantidade de área disponível para expandir as atividades agrícolas fica menor a cada dia. Por isso, existe uma demanda crescente de tecnologias para auxiliar os produtores no aumento da eficiência e produtividade de suas lavouras. Recentemente, com a evolução dos Veículos Aéreos não Tripulados, tem crescido o emprego de imagens aéreas agrícolas para monitorar a saúde de lavouras onde a vitalidade da vegetação é calculada utilizando métodos bem conhecidos como *Normalized Difference Vegetation Index*. Entretanto, somente os índices de vegetação não são suficientes para determinar o conjunto de decisões a serem tomadas pelo produtor. Como alternativa a esta limitação a região produtiva em análise é classificada e dividida em Zonas de Manejo que apontarão ao fazendeiro quais estratégias deverão ser adotadas na correção do solo e tratamento da lavoura em locais específicos. No sentido de agilizar este processo, neste trabalho é proposto um algoritmo para geração automática das zonas de manejo de uma região imageada por VANT. Foi empregado no trabalho técnicas de pré-processamento de imagens no intuito de preparar os dados para o algoritmo de agrupamento dos mesmos, no caso o *K-means*. Os resultados obtidos se mostraram satisfatórios quando analisados por especialistas.

Palavras-chaves: Agricultura de Precisão. Monitoramento Remoto. VANTs. Zonas de Manejo. Índices de Vegetação.

Abstract

The continuous growth of the World population results in a bigger need of food production, however the amount of area available to expand farming activities gets smaller every day. That is why there is a growing demand for techniques to help farmers improve the efficiency of their crops. Recently, with an evolution of Unmanned Aerial Vehicles, the use of agricultural aerial images to monitor crop health where vegetation vitality is calculated using well-known methods such as Normalized Difference Vegetation Index, has been growing. Nevertheless, only these vegetation indexes are not enough to determine the set of decisions to be taken by the producer. As an alternative to this limitation, the productive region under analysis is classified and divided into Management Zones that will indicate to the farmer what strategies should be adopted in the soil correction and treatment of the crop, in site specific. For this reason, to streamline this process, it is proposed in this work an algorithm for automatic generation of the MZ of an UAV-imaged region, it was used in the work techniques of pre-processing of images in order to prepare the data for the data clustering algorithm , in this case the K-means. The results obtained were satisfactory when analyzed by specialists.

Key-words: Precision Agriculture. Remote Sensing. UAVs. Management Zones. Vegetation Indexes.

Lista de ilustrações

Figura 1 – Estrutura imagem monocromática	13
Figura 2 – Estrutura imagem RGB	13
Figura 3 – Matriz pré filtro	15
Figura 4 – Região de aplicação do filtro	15
Figura 5 – Matriz pós filtro normalizado	15
Figura 6 – Mediana da região selecionada	16
Figura 7 – Matriz pós filtro mediano	16
Figura 8 – Distribuição gaussiana em 2 dimensões (www.researchgate.net)	16
Figura 9 – Matriz pós Filtro Gaussiano	17
Figura 10 – Gato em escala de cinza (peakpx.com)	17
Figura 11 – Histograma da Fig.10	17
Figura 12 – Fig. 10 equalizada	18
Figura 13 – Histograma da Fig.12	18
Figura 14 – Cubo RGB (https://goo.gl/bebjMD)	18
Figura 15 – Cilindro HSV (https://goo.gl/yx8FNp)	19
Figura 16 – Exemplo de aplicação de um mapa de cor(https://goo.gl/yZdWH1)	20
Figura 17 – Dados a serem classificados	22
Figura 18 – Centros iniciais (4, 7) e (8, 4)	22
Figura 19 – Classificação Inicial	22
Figura 20 – Centros após 1 iteração (3, 4) e (6.8, 5.4)	22
Figura 21 – Classificação após 1 iteração	22
Figura 22 – Centros após 2 iterações (2.8, 3.4) e (7, 6)	22
Figura 23 – Matriz com canais RGNIR	24
Figura 24 – NDVI da Fig. 23	24
Figura 25 – Canon S110 (canon.com)	26
Figura 26 – Parrot® Sequoia (parrot.com)	26
Figura 27 – Micasense® Red Edge (micasense.com)	26
Figura 28 – Phantom 4 pro (dji.com)	27
Figura 29 – Sx2 (sensix.com.br)	27
Figura 30 – Pseudocódigo do algoritmo	30
Figura 31 – Fluxograma do algoritmo	30
Figura 32 – NDVI	32
Figura 33 – NDVI com filtro normalizado	32
Figura 34 – NDVI com filtro gaussiano	32
Figura 35 – NDVI com filtro mediano	32
Figura 36 – Matriz IV	34

Figura 37 – Grid da Fig. 36	34
Figura 38 – Ortomosaico NIRGB	36
Figura 39 – Recortando o ortomosaico	36
Figura 40 – Ortomosaico Recortado	36
Figura 41 – NDVI	37
Figura 42 – NDVI Colorido	37
Figura 43 – Grid 30x30m	37
Figura 44 – NDVI com filtro mediano 100	38
Figura 45 – NDVI equalizado com filtro mediano 100	38
Figura 46 – Histograma da Fig. 44	38
Figura 47 – Histograma da Fig. 45	38
Figura 48 – Grupos iniciais do <i>K-means</i>	38
Figura 49 – Grupos finais do <i>K-means</i>	38
Figura 50 – Zonas de Manejo com filtro mediano de tamanho 100	39
Figura 51 – ZM sem filtro e equalização	39
Figura 52 – ZM sem filtro	39
Figura 53 – ZM - filtro mediano 50	40
Figura 54 – ZM - filtro mediano 100	40
Figura 55 – ZM - filtro normalizado 100	40
Figura 56 – ZM - filtro gaussiano 100	40
Figura 57 – Ortomosaico de soja em 01/12/2017 na Bahia	41
Figura 58 – NDVI de soja	41
Figura 59 – ZM de Soja	41
Figura 60 – Grid de Soja	41
Figura 61 – Variação de vigor na soja	42
Figura 62 – Nematoides na soja	43
Figura 63 – Linhas duplas na soja	43
Figura 64 – Manchas de solo na soja	44
Figura 65 – NDVI de uma plantação de milho	44

Lista de abreviaturas e siglas

AP	Agricultura de Precisão
GSD	<i>Ground Sampling Distance</i>
HSV	<i>Hue, Saturation e Value</i>
ID	Imagem Digital
IV	Índice de Vegetação
NIR	<i>Near Infra-Red</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
PDI	Processamento Digital de Imagem
RGB	<i>Red, Green, Blue</i>
VANTs	Veículos Aéreos Não Tripulados
VARI	<i>Visible Atmospherically Resistant Index</i>
ZE	Zonas Efetivas
ZM	Zonas de Manejo

Sumário

	Introdução	11
1	EMBASAMENTO TEÓRICO	13
1.1	Imagens Digitais	13
1.2	Processamento Digital de Imagens	13
1.2.1	Filtros digitais	14
1.2.1.1	Filtro normalizado	14
1.2.1.2	Filtro mediano	15
1.2.1.3	Filtro gaussiano	16
1.2.2	Histograma	17
1.2.3	Equalização	18
1.2.4	Modelo de cores	18
1.2.5	Mapa de cores	20
1.3	<i>K-Means</i>	21
1.4	Agricultura de Precisão	23
1.4.1	Índices de Vegetação	23
1.5	Sensores	25
1.6	VANTs	26
2	TRABALHOS CORRELATOS	28
3	METODOLOGIA	30
3.1	Introdução ao algoritmo	30
3.2	Descrição do algoritmo	31
3.3	Resultados secundários	33
4	RESULTADOS E DISCUSSÕES	35
4.1	Configurações	35
4.2	Pré Processamento	35
4.3	Aplicação do algoritmo	36
4.4	Importância dos Passos	38
4.5	Estudo de caso de mapeamentos utilizando o NDVI	41
	Conclusão	45
	REFERÊNCIAS	47

Introdução

O crescimento contínuo da população mundial resulta em um aumento da necessidade de produção de alimentos, entretanto a quantidade de área disponível para expandir as atividades agrícolas se torna menor a cada dia. Por isso, existe uma demanda de novas técnicas para auxiliar os fazendeiros a melhorar a eficiência de suas lavouras (TRIPICCHIO et al., 2015).

Um conceito criado para ajudar a aumentar a produtividade das plantações é a Agricultura de Precisão (AP), de acordo com (ZHANG; KOVACS, 2012) a AP consiste na aplicação de técnicas geoespaciais e sensores, como imagens aéreas e GPS, para identificar variações na lavoura e então utilizar diferentes abordagens para tratar os diversos problemas.

Esta variação de manejo no espaço de acordo com (BASSO et al., 2001) é provado ser efetivo em aumentar a produção das plantações. Uma das razões para isto é que quando a quantidade errada, menos ou mais, de agrotóxicos é aplicada a produtividade da lavoura diminui.

E ainda, AP não só aumenta a produtividade da plantação, mas também reduz o uso de agrotóxicos (fertilizantes, pesticidas, nematicidas) o que resulta em uma redução do impacto ambiental (BONGIOVANNI; LOWENBERG-DEBOER, 2004) e custo de produção.

Para colocar em prática a AP é necessário utilizar de ferramentas que fornecem informações sobre a plantação, tornando possível a identificação das variações nas lavouras.

Por esta razão, o uso de Veículos Aéreos não Tripulados (VANTs) para obter informações através de imagens aéreas está sendo bastante explorado, como pode ser visto em (ZHANG; KOVACS, 2012)(HONKAVAARA et al., 2013)(NAVARRO ALISSON GARCIA, 2015)(ALVES RICARDO VICENTE FERREIRA, 2015). As vantagens de se utilizar esta tecnologia é que ela é fácil de ser utilizada, tem várias aplicações, é totalmente portátil, e apresenta baixo custo financeiro.

Com as imagens aéreas capturadas com os VANTs é possível então calcular alguns índices de vegetação da lavoura, como o *Normalized Difference Vegetative Index* (NDVI) e *Visible Atmospherically Resistant Index* (VARI), que em resumo são utilizados para indicar a vitalidade da plantação e consequentemente inferir a variação de produtividade da lavoura (TEAL et al., 2006). E assim, com esta informação é possível agrupar espacialmente regiões que podem ser consideradas de característica similares em relação ao Índice de Vegetação, e então definir Zonas de Manejo (ZM) específicas para cada região da lavoura.

Uma ZM é uma área da plantação que necessita de tratamento específico e, uma vez

que podem existir áreas com as mesmas característica porém espacialmente desconectadas, uma ZM pode aparecer em mais de uma região da plantação. Uma única lavoura pode ser dividida em várias ZM diferentes, porém de acordo com a opinião de especialistas usualmente não se divide em mais de 5.

Estas zonas são úteis pois permitem ao fazendeiro variar os cuidados tomados dentro da plantação, de forma que em regiões com vitalidade maior seja aplicado menos agrotóxicos e a necessidade de análises de solo, foliar e outras seja menor, e de maneira antagônica nas áreas de menor vitalidade.

Devido a grande utilidade da definição de ZM e a facilidade de se utilizar VANTs para o monitoramento remoto, este trabalho tem como objetivo principal o desenvolvimento de um algoritmo de processamento digital de imagens para definir Zonas de Manejo.

Para isso, deve-se especificar o *hardware* mínimo necessário para captura das imagens, as etapas de pré processamento das mesmas, além do algoritmo de agrupamento de dados utilizado.

Tendo em vista as características do problema abordado é apresentado como solução o classificador *K-means* para segmentar as ZM, uma vez que o mesmo é estável, eficiente e bem conhecido.

1 Embasamento Teórico

1.1 Imagens Digitais

Para iniciar o entendimento de Processamento Digital de Imagens (PDI) o termo Imagem Digital (ID) pode ser definido como um conjunto de dados binários que representam uma cena bidimensional, onde cada elemento é denominado de *pixel*.

Em imagens monocromáticas (Fig. 1) o valor de cada pixel é definido por uma função $f(x, y)$, onde x e y descrevem a posição de um pixel, que é proporcional a intensidade luminosa daquele ponto na cena. Para imagens com mais de um canal, como o RGB (*Red*, *Green*, *Blue*) (Fig. 2), cada banda possui uma função $f(x, y)$ diferente (FILHO; NETO, 1999).




Figura 1 – Estrutura imagem monocromática




Figura 2 – Estrutura imagem RGB

1.2 Processamento Digital de Imagens

Com o conceito de ID entendido pode-se definir PDI como sendo um processo de manipulação de dados que tem como entrada e saída ID (FILHO; NETO, 1999).

O PDI é uma área do conhecimento que tem avançado significativamente desde os anos 60, inicialmente isto ocorreu devido a corrida espacial dos Estados Unidos da América onde existia um grande interesse em aumentar a qualidade e corrigir distorções das imagens capturadas pelas sondas espaciais, além do aumento significativo do poder de

processamento computacional disponível na época, capacidade que só vem aumentando desde então.

E ainda, de acordo com (FILHO; NETO, 1999) outro motivo para os avanços nesta área é o crescente interesse das pessoas por PDI devido a sua vasta gama de aplicações, como na medicina para realizar diagnósticos, na indústria para automatização de processos e controle de qualidade, na agricultura para monitoramento remoto, entre outras inúmeras aplicações.

A área de PDI é oriunda da área de Processamento Digital de Sinais, o que é natural de se compreender, uma vez que a imagem nada mais é do que a resposta emitida por um conjunto de sensores. Por esta razão, faz parte do conjunto de técnicas e algoritmos de PDI técnicas oriundas da área de Processamento de Sinais, tais como: filtros de banda (passa-baixa, passa-faixa, passa-alta), filtros lineares, filtros não lineares, técnicas de convolução, entre outras. Além de um conjunto de operações criadas especificamente para a área de PDI, tais como: transformações morfológicas, transformações geométricas, equalização entre outras.

1.2.1 Filtros digitais

Os filtros digitais tem como intuito principal remover ruídos das imagens, existem inúmeros tipos de filtros, como o Filtro Normalizado (MCDONNELL, 1981), o filtro mediano (GALLAGHER; WISE, 1981) e o filtro gaussiano (LEE, 1983) que são exemplos de filtros passa-baixa, ou seja, atenuam os componentes de alta frequência da imagem. Tais filtros podem tanto ser aplicados no domínio da frequência a partir da aplicação na imagem da transformada bidimensional de Fourier ou então através da aplicação de filtros convolutivos que, normalmente se baseiam no conceito de filtros derivativos e lineares.

1.2.1.1 Filtro normalizado

O filtro normalizado ou filtro da média, é um filtro linear que simplesmente substitui o valor de cada pixel pela média dos pixels vizinhos que estão dentro de um quadrado de tamanho pré determinado.

Na Fig. 3 pode ser visualizada uma aplicação do referido filtro, primeiramente seleciona-se o pixel a ser filtrado e o tamanho do filtro aplicado como na Fig. 4.

Então, o valor pixel é substituído pela média dos pixels dentro da região selecionada e seu resultado pode ser visto na Fig. 5. Este processo é então repetido para todos os pixels da imagem.

A vantagem do filtro normalizado é que ele é bastante simples, por isso a sua aplicação apresenta baixo custo computacional em relação a outros filtros. Porém, sua desvantagem é que o mesmo sofre bastante influência de *outliers*.

3	4	1	3
7	2	123	8
5	4	7	8
2	3	6	1
9	5	7	1

Figura 3 – Matriz pré filtro

3	4	1	3
7	2	123	8
5	4	7	8
2	3	6	1
9	5	7	1

Figura 4 – Região de aplicação do filtro

3	4	1	3
7	17	123	8
5	4	7	8
2	3	6	1
9	5	7	1

Figura 5 – Matriz pós filtro normalizado

1.2.1.2 Filtro mediano

O filtro mediano é um filtro não linear, filtros que utilizam uma função não linear para calcular o valor dos pixels, que substitui o valor de cada pixel pela mediana dos pixels vizinhos que se encontram em uma região pré selecionada.

Como ilustração do seu funcionamento pode ser visualizada o efeito da sua aplicação na Fig. 3 tendo como região selecionada aquela representada na Fig. 4.

E assim, o valor do pixel destacado foi substituído pela mediana (Fig. 6) dos pixels vizinhos, a matriz resultante pode ser observada na Fig. 7. O procedimento deve ser repetido para todos os pixels na imagem.

O filtro mediano apresenta como vantagem a sua robustez em relação a *outliers*, entretanto não é recomendado a aplicação do mesmo em imagens com os valores de pixels

bastante variados.

1	2	3	4	4	5	7	7	123
---	---	---	---	---	---	---	---	-----

Figura 6 – Mediana da região selecionada

3	4	1	3
7	4	123	8
5	4	7	8
2	3	6	1
9	5	7	1

Figura 7 – Matriz pós filtro mediano

1.2.1.3 Filtro gaussiano

O filtro gaussiano tem como princípio de funcionamento a aplicação de uma distribuição gaussiana de duas dimensões para cada pixel, delimitando o alcance da distribuição dentro de uma região pré determinada.

Uma distribuição gaussiana tem a forma representada na Fig. 8 e é descrita pela eq. 1.1, onde x e y são respectivamente as distâncias nos eixos X e Y e σ é o desvio padrão da distribuição gaussiana.




Figura 8 – Distribuição gaussiana em 2 dimensões (www.researchgate.net)

$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp^{-\frac{x^2}{2\sigma^2}} \quad (1.1)$$

Este filtro foi aplicado na matriz representada na Fig. 3 com a região em destaque na Fig. 4. O resultado deste procedimento pode ser observado na Fig. 9, é importante lembrar que este processo deve ser repetido para todos os pixels da imagem.

3	4	1	3
7	3	123	8
5	4	7	8
2	3	6	1
9	5	7	1

Figura 9 – Matriz pós Filtro Gaussiano

Este filtro apresenta bons resultados, porém seu custo computacional é bastante elevado.

1.2.2 Histograma

Um histograma é uma representação gráfica do número de pixels por intensidade luminosa existentes em uma imagem, com este recurso é possível ter ideia da distribuição de cores e contraste de uma imagem. Com o intuito de exemplificar o histograma da Fig. 10 foi calculado e mostrado na Fig. 11.



Figura 10 – Gato em escala de cinza (pe-akpx.com)




Figura 11 – Histograma da Fig. 10

1.2.3 Equalização

A equalização é um processo que visa aumentar o contraste da imagem, ou seja, distribuir os pixels de maneira mais uniforme no espaço da intensidade luminosa. O resultado deste processo pode ser observado através da comparação das imagens e dos seus respectivos histogramas antes (figs.10 e 11) e após equalização (figs. 12 e 13).



Figura 12 – Fig. 10 equalizada




Figura 13 – Histograma da Fig.12

1.2.4 Modelo de cores

Como explicado na seção 1.1 uma ID pode ser monocromática ou colorida, quando se tem cor é necessário adotar algum modelo de representação de cores para ser possível expressar numericamente a coloração. Em vista disto, vários modelos para representar cores foram criados, como o RGB, HSV (*Hue, Saturation, Value*), CIE XYZ, CIE L*a*b, entre outros.

O modelo de cores RGB é um dos mais utilizados em câmeras e monitores (FILHO; NETO, 1999), por isso as imagens digitais geralmente estão neste formato quando possuem cor. Este formato de cores pode ser representado por um cubo (Fig. 14) inserido em um sistema cartesiano, onde os eixos representam a cor vermelha, azul e verde (cores primárias). Todas as outras cores podem ser representadas através da combinação das cores primárias.




Figura 14 – Cubo RGB (<https://goo.gl/bebjMD>)

O sistema HSV por sua vez é composto pelas componentes *Hue*, indica o tipo de cor, *Saturation*, representa o tom de cinza da cor, e *Value*, define a intensidade do brilho da cor. Esta representação tenta representar de maneira mais próxima a forma que os humanos enxergam (FILHO; NETO, 1999).

Este modelo de cores pode ser representado por um cilindro (Fig. 15), onde o *Hue*, *Saturation* e *Value* são representados pela dimensão angular, radial e vertical, respectivamente.




Figura 15 – Cilindro HSV (<https://goo.gl/yx8FNp>)

Devido a maior proximidade do HSV a forma como os humanos percebem as cores, algumas operações, como a segmentação e interpolação de cores, em imagens são melhores realizadas quando estão neste espaço de cores. Por isso, muitas vezes em PDI é necessário realizar a conversão entre esses dois modelos.

A conversão de RGB para HSV, com $R, G, B, V, S \in [0, 1]$ e $H \in [0^\circ, 360^\circ]$, é feita da seguinte forma:

Primeiramente, adota-se *Max* e *Min* como sendo os valores de máximo e mínimo, respectivamente, entre R, G, B . Então, as equações 1.2, 1.3 e 1.4 são utilizadas para encontrar o H, S, V (FILHO; NETO, 1999).

$$H = \begin{cases} 60 \times \frac{G-B}{Max-Min} + 0, & \text{se } Max = R \text{ e } G \geq B \\ 60 \times \frac{G-B}{Max-Min} + 360, & \text{se } Max = R \text{ e } G < B \\ 60 \times \frac{B-R}{Max-Min} + 120, & \text{se } Max = G \\ 60 \times \frac{R-G}{Max-Min} + 240, & \text{se } Max = B \end{cases} \quad (1.2)$$

$$S = \frac{Max - Min}{Max} \quad (1.3)$$

$$V = Max \quad (1.4)$$

O caminho inverso, de HSV para RGB, pode ser encontrado seguindo as equações 1.5 - 1.9.

$$C = V \times S \quad (1.5)$$

$$X = C \times (1 - |\frac{H}{60^\circ} \bmod 2 - 1|) \quad (1.6)$$

$$m = V - C \quad (1.7)$$

$$(R', G', B') = \begin{cases} (C, X, 0), & 0^\circ \leq H < 60^\circ \\ (X, C, 0), & 60^\circ \leq H < 120^\circ \\ (0, C, X), & 120^\circ \leq H < 180^\circ \\ (0, X, C), & 180^\circ \leq H < 240^\circ \\ (X, 0, C), & 240^\circ \leq H < 300^\circ \\ (C, 0, X), & 300^\circ \leq H < 360^\circ \end{cases} \quad (1.8)$$

$$(R, G, B) = (R' + m, G' + m, B' + m) \quad (1.9)$$

1.2.5 Mapa de cores

Uma mapa de cor nada mais é que uma função que mapeia os pixels de uma imagem de entrada para uma imagem de saída. Por exemplo, pequenas variações em imagens em escala de cinza não são muito perceptíveis ao olho humano, por isso aplica-se um mapa de cor nestas para deixar estas variações mais destacadas como pode ser visto na Fig. 16 .




Figura 16 – Exemplo de aplicação de um mapa de cor(<https://goo.gl/yZdWH1>)

Para gerar estes mapas de cores, muitas vezes, se tem apenas alguns valores de pixels associados a algumas cores, por exemplo os valores de pixels 0, 0.5 e 1 associados as

cores puras vermelho, amarelo e verde, respectivamente. Então, é necessário interpola-los para gerar um mapa de cor completo, como é mais usual as cores estarem descritas no modelo RGB, e o mesmo não representa de maneira fiel como os humanos percebem as cores, é necessário converter estas cores em HSV para só então realizar a interpolação, e em seguida converter de volta em RGB para gerar o mapa de cor.

1.3 *K-Means*

O *K-means* é um algoritmo utilizado para realizar o agrupamento de dados. Seu objetivo é dividir um conjunto contendo N dados em K grupos. Este procedimento é realizado automaticamente em função do grau de semelhança entre os dados, sendo que a definição de semelhança depende do problema analisado.

Em (JAIN, 2010) o *K-means* é descrito formalmente como um algoritmo que objetiva dividir os dados de forma a reduzir o erro quadrático entre a média empírica do grupo e a média dos pontos classificados no grupo.

Para isso, primeiramente defini-se $X = \{x_i\}, i = 1, \dots, n$ como o conjunto de dados n -dimensionais que se deseja agrupar em K grupos, e o conjunto de grupos definido por $C = \{c_k\}, k = 1, \dots, K$.

Em seguida, o erro quadrático entre a média empírica do grupo e a média dos pontos do grupo é definida seguindo a eq. 1.10. Onde μ_k é a média empírica do grupo e x_i o valor do dado i .

$$J(c_k) = \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (1.10)$$

Tendo em vista que objetivo do algoritmo é minimizar a soma dos erros quadráticos de todos os grupo, e não de um grupo individual, a eq. 1.11 é a qual se deseja minimizar.

$$J(C) = \sum_{k=1}^K \sum_{x_i \in c_k} \|x_i - \mu_k\|^2 \quad (1.11)$$

O *K-means* é iniciado com K grupos pré-definidos, os dados são então associados a cada um destes grupos de forma a minimizar o erro quadrático, em seguida a média de cada grupo é recalculada e estes valores são os novos centros dos grupos. Então, os dois últimos passos são repetidos até o algoritmo convergir para um erro pré-determinado, ou realizar um número pré-definido de iterações.

Para o melhor entendimento do algoritmo o mesmo foi representado graficamente nas figuras 17 - 22. Na Fig. 17 está representado o conjunto de dados que se deseja classificar em 2 grupos, primeiramente os centros são configurados em uma posição arbitrária (Fig.

18), em seguida os dados são classificados no grupo mais próximo (Fig. 19), então os centros são recalculados (Fig. 20), depois os dados são novamente classificados (Fig. 21) e os centros recalculados (Fig. 22). Após a segunda iteração os centros convergem, por isso o algoritmo foi finalizado.




Figura 17 – Dados a serem classificados




Figura 18 – Centros iniciais (4, 7) e (8, 4)




Figura 19 – Classificação Inicial




Figura 20 – Centros após 1 iteração (3, 4) e (6.8, 5.4)




Figura 21 – Classificação após 1 iteração




Figura 22 – Centros após 2 iterações (2.8, 3.4) e (7, 6)

O *K-means* tem alguns parâmetros que podem ser ajustados, sendo eles o número de grupos, o estado inicial e o método para calcular a erro, também chamado de distância.

Geralmente o valor de K e o estado inicial são definidos de forma experimental, e o método para calcular a distância geralmente é o modelo Euclidiano.

1.4 Agricultura de Precisão

Na agricultura, independente da cultura trabalhada, a área de plantio utilizada pode se mostrar bastante heterogenia, o que gera uma demanda de tratamentos diferenciados ao longo da lavoura. Aqueles agricultores que cultivam áreas pequenas e ainda trabalham de forma manual conseguem perceber este fenômeno mais facilmente. Porém, à medida que se aumenta a escalabilidade, tal percepção se torna mais complexa e as variações de solo e consequente especificidades de correção do mesmo acabam por se tornar imperceptíveis. (MOLIN; AMARAL; COLAÇO, 2015).

Com o intuito de explorar e superar tais deficiências, surgiu uma nova área de pesquisa e técnicas de manejo de solo que atualmente é conhecida como Agricultura de Precisão (AP). Segundo (MOLIN; AMARAL; COLAÇO, 2015) AP é uma abordagem que tem como princípio a gestão das lavouras com um detalhamento elevado que permite trata-la de forma variável suprimindo assim as suas necessidades.

De acordo com (ZHANG; KOVACS, 2012) a AP consiste na aplicação de técnicas geoespaciais e sensores, como imagens aéreas e GPS, para identificar variações na lavoura e então utilizar diferentes abordagens para tratar os diferentes problemas.

E ainda, de acordo com a Comissão Brasileira de Agricultura de Precisão, a definição de AP é : "Um conjunto de ferramentas e tecnologias aplicadas para permitir um sistema de gerenciamento agrícola baseado na variabilidade espacial e temporal da unidade produtiva, visando ao aumento de retorno econômico e à redução do impacto ao ambiente."

1.4.1 Índices de Vegetação

Os Índices de Vegetação (IV) são transformações espectrais, de um ou mais canais, utilizados para inferir informações das propriedades das vegetações, possibilitando assim a comparação espacial e até mesmo temporal das mesmas (HUETE et al., 2002).

Como o IV é apenas uma transformação de canais espectrais o seu resultado não tem um viés, ou seja, não existe nenhuma modificação em função da plantação, solo ou condições climáticas.

Atualmente, existem diversos Índices de Vegetação conhecidos e estudados, como *Soil-adjusted vegetation index* (SAVI) (HUETE, 1988), *Atmospherically Resistant Vegetation Index* (ARVI) (KAUFMAN; TANRE, 1992), *Visible Atmospherically Resistant Index* (VARI) (GITELSON et al., 2002), *Normalized Difference Vegetation Index* (NDVI) (TEAL

et al., 2006). Em vista do grande número de IV disponíveis, este trabalho explora mais detalhadamente a aplicação do VARI e do NDVI.

O VARI é calculado utilizando os canais Vermelho, Verde e Azul (RGB) como é mostrado na eq. 1.12, este índice tem como intuito verificar o quão verde é a vegetação.

$$VARI = \frac{Verde - Vermelho}{Verde + Vermelho - Azul} \quad (1.12)$$

Já o NDVI indica a vitalidade e a densidade de verde de uma área, e seu calculo é feito originalmente utilizando os bandas de Infra Vermelho Próximo (NIR), comprimento de onda entre 700 nm e 2500 nm, e Vermelho, ou alternativamente quando não se tem o vermelho utiliza-se o NIR e o Azul, como pode ser visto nas eq. 1.13 e 1.14.

$$NDVI = \frac{NIR - Vermelho}{NIR + Vermelho} \quad (1.13)$$

$$NDVI = \frac{NIR - Azul}{NIR + Azul} \quad (1.14)$$

Com o intuito de exemplificar o calculo do NDVI a equação 1.13 foi aplicada na Fig. 23 assumindo os canais Vermelho, Verde e Infravermelho próximo, respectivamente. O resultado pode ser visto na Fig. 24.

(3,4,3)	(4,2,7)	(1,3,4)
(3,1,9)	(2,2,5)	(1,1,5)
(5,3,4)	(2,1,9)	(1,5,10)

Figura 23 – Matriz com canais RGNIR

0	0.27	0.6
0.5	0.43	0.67
-0.11	0.63	0.82

Figura 24 – NDVI da Fig. 23

O IV SAVI é encontrado seguindo a eq. 1.15, onde o L é o fator de correção do brilho do solo, sendo que, seu valor varia de acordo com a cobertura vegetal. De forma que, para regiões com muita cobertura vegetal adota-se $L = 0$, em contrapartida para áreas sem cobertura verde $L = 1$.

Ao comparar a formula do SAVI e NDVI percebe-se que ambas são iguais quando $L = 0$, isto ocorre uma vez que a primeira foi desenvolvida como sendo uma modificação

da segunda, com o intuito de corrigir a influência do brilho solo quando a cobertura vegetal é baixa.

$$SAVI = \frac{NIR - Vermelho}{NIR + Vermelho + L} * (1 + L) \quad (1.15)$$

Por sua vez, o ARVI é utilizado como alternativa ao NDVI, com o intuito de minimizar as influências dos efeitos atmosféricos presentes no calculo do último. Uma vez, que estas interferências acontecem porque o canal vermelho sofre bastante influência dos efeitos atmosféricos em comparação a banda NIR, subtrai-se a banda azul do mesmo como uma tentativa de mitigar esta influência.

Desta forma, o ARVI é calculado a partir da eq. 1.16.

$$ARVI = \frac{NIR - (Vermelho - Azul)}{NIR + (Vermelho - Azul)} \quad (1.16)$$

1.5 Sensores

Sensores são elementos que estão diretamente afetados pelo o que está sendo medido. De maneira específica, um sensor elétrico converte a quantidade a ser medida em um sinal elétrico de saída (DYER, 2004).

Na Agricultura de Precisão com o intuito de entender melhor a lavoura diversos tipos de sensores podem ser utilizados, como medidor de umidade, medidor de condutividade, medidor de produtividade, satélites e câmeras, entre outros.

Recentemente, a aplicação de sensores ópticos na agricultura, como satélites e câmeras, tem sido largamente estudados devido a sua facilidade de utilização e a rapidez em se obter resultados, o que possibilita aos produtores realizarem ações necessárias de maneira ágil. As técnicas provenientes do emprego deste tipo de sensor na agricultura estão classificadas dentro de monitoramento remoto (CAMPBELL; WYNNE, 2011).

No início da exploração das técnicas de monitoramento remoto utilizava-se bastante as imagens provenientes de satélites como o MODIS (NASA, 2017) e o Landsat (USGS, 2017). Entretanto, esta forma de aquisição de imagens apresenta problemas, como o grande intervalo de tempo para se tirar fotos de um mesmo lugar que pode chegar até 2 semanas, o alto custo para se adquirir imagens de alta resolução, a maior probabilidade de interferências atmosféricas, como nuvens e sombras, devido a altitude elevada dos mesmos.

Sendo assim, começou-se a explorar a utilização de câmeras embarcadas em Veículos Aéreos não Tripulados para realizar o monitoramento remoto. Desta forma, para efetivamente capturar as imagens é necessário embarcar um sensor (câmera) voltado para

baixo no VANT, estes podem ser capazes de capturar diversos conjuntos de espectros misturando os canais de Vermelho, Verde, Azul, *Red Edge* e *Near Infrared*.

Como exemplo temos um modelo de câmera fotográfica produzida pela empresa Canon, a Canon S110 (Fig. 25), que captura os canais RGB e pode ser modificada para capturar os espectros NIRGB, ou o sensor Sequoia produzido pela Parrot® (Fig. 26) que captura as bandas RGNIR e *Red Edge*, ou a câmera fabricada pela Micasense® chamada Red Edge (Fig. 27) que captura os canais RGBNIR e *Red Edge*.



Figura 25 – Canon S110 (canon.com)

Figura 26 – Parrot® Sequoia (parrot.com)



Figura 27 – Micasense® Red Edge (micasense.com)

1.6 VANTs

Atualmente, o uso de VANTs para Agricultura de Precisão tem aumentado, principalmente devido as facilidades providas por esta tecnologia, como a praticidade de realizar voos quando desejar, o pequeno intervalo de tempo entre capturas de imagem, a alta resolução das imagens capturadas que podem chegar facilmente à um *Ground Sampling Distance* (GSD), distância entre o centro de dois pixels medidos no solo, de 5cm. Inúmeros pesquisadores tem explorado esta tecnologia e apresentado resultados interessantes (ZHANG; KOVACS, 2012), (NAVARRO ALISSON GARCIA, 2015), (PRIMICERIO et al., 2012).

Os VANTs podem ser classificados em dois principais grupos: multi-rotores (ex: Fig. 28) ou de asa-fixa (ex: Fig. 29). Entretanto, para a AP o uso de VANTs multi-rotores apresenta algumas desvantagens em relação aos de asa-fixa, a principal delas é a baixa relação custo benefício devido ao maior consumo de energia proveniente do uso de mais motores.



Figura 28 – Phantom 4 pro (dji.com)



Figura 29 – Sx2 (sensix.com.br)

2 Trabalhos Correlatos

A utilização de imagens digitais para calcular ZM tem sido explorada em inúmeros trabalhos realizados por pesquisadores da área como pode ser observado em uma breve revisão da literatura. Em (LI et al., 2007), por exemplo, é apresentado um algoritmo onde são considerados cinco atributos de solo, informação do NDVI, condutividade elétrica do solo, nitrogênio total, matéria orgânica e capacidade de troca de *cation*. A pesquisa utiliza análise de componentes principais (PCA) para escolher um subgrupo de atributos menores, resultando em 2 componentes principais (subgrupo) que são usados como entrada para um algoritmo de agrupamento *c-means fuzzy* para determinar as Zonas de Manejo. Este trabalho tem como desafio a necessidade de vários tipos de dados da lavoura, como atributos de solo, NDVI e condutividade elétrica, para determinar as ZM. Isto é problemático uma vez que realizar estas amostras é uma tarefa bastante dispendiosa em termos financeiros e de tempo. Em contrapartida, uma característica bastante interessante deste trabalho que merece ser melhor explorada é a forma que é feito a verificação de qualidade dos resultados. Vários atributos químicos do solo, previamente aferidos, e os dados de produtividade são associados a cada ZM encontrada, em seguida é realizado uma análise de variância para distinguir e avaliar estatisticamente as ZM.

Em (PEDROSO et al., 2010) é apresentado um algoritmo de segmentação inspirado em um algoritmo de processamento de imagem utilizado para mesclagem de regiões, o agrupamento é feito mesclando-se as regiões próximas com atributos semelhantes, as coordenadas espaciais são usadas apenas para delimitar a área onde a busca acontecerá. Como estudo de caso foram utilizadas imagens aéreas de vinhedos localizados em Olite no Sul de Navarre na Espanha. Para o efeito de comparação com outros métodos de classificação o autor aplicou, além da metodologia descrita, dois algoritmos de agrupamento baseados no K-means para gerar as ZM. Então, ao confrontar os resultados obtidos pelos 3 métodos distintos o autor concluiu que o algoritmo de segmentação obteve resultados melhores que os demais. Entretanto, isto pode ter sido influenciado principalmente por 2 fatores, sendo eles, a ausência de etapas de pré processamento na aplicação dos algoritmos baseados no *K-means*, além de uma metodologia inadequada de comparação de resultados. Para realizar a comparação foi introduzido um conceito chamado de Zona Efetiva (ZE), este determina que uma vez não sendo possível variar o tratamento em uma região com área menor que 0.1 ha, devido a existência de limitações tecnológicas, somente as regiões com áreas superiores a este limiar devem ser consideradas como classificadas com sucesso e são denominadas de ZE. E ainda, foi calculado pra cada resultado dos algoritmos distintos uma parâmetro que indica a correlação da variância da circunferência dos vinhedos, de forma que quando mais próximo de 1 melhor. Em seguida, utilizando os 3 métodos as Zonas

de Manejos foram encontradas variando-se o número de zonas desejado de 2 até 24 em intervalos de 2, e então as Zonas Efetivas e o indicador de correlação foram calculadas para cada um destes. E assim, com estes parâmetros determinados comparou-se o indicador de correlação da variância da circunferência dos vinhedos dos resultados cujo o número de ZE eram próximos, por exemplo, no algoritmo de segmentação foi utilizado um resultado com número de zonas igual a 24 e 28 ZE, já no caso do K-means optou-se pelo mapa com número de zonas igual a 4 e ZE de 30, e uma vez que a variância do resultado proveniente da segmentação foi melhor o mesmo foi escolhido como algoritmo mais adequado. Um ponto que poderia ter sido melhor explorado no trabalho (PEDROSO et al., 2010) é a metodologia empregada na análise dos resultados obtidos. Em sua pesquisa os autores comparam mapas com característica diferentes utilizando parâmetros pouco conclusivos o que dificulta uma avaliação qualitativa dos resultados obtidos.

Esses dois trabalhos sintetizam os tipos de pesquisas que tem sido realizadas na busca de determinação de ZM a partir de imagens digitais (CID-GARCIA et al., 2013) (ROUDIER et al., 2008) (RUSS; KRUSE, 2011), diante do exposto é possível concluir a efetividade do uso de algoritmos de agrupamento de dados para a determinação de ZM a partir de imagens aéreas, porém percebe-se que a existência de espaço para o aprimoramento das estratégias utilizadas, seja explorando novas técnicas ou tratando de novos problemas oriundos de características específicas às regiões tratadas. Outro aspecto a ser explorado é a definição de metodologias mais robustas para validação dos resultados obtidos, permitindo assim a comparação de métodos distintos.

3 Metodologia

3.1 Introdução ao algoritmo

O objetivo final deste trabalho é o desenvolvimento de um algoritmo capaz de gerar ZM a partir de imagens aéreas, porém além deste resultado o mesmo foi incrementado para fornecer também os mapas do Índice de Vegetação representado por uma grade de cores.

O pseudocódigo do algoritmo desenvolvido esta descrito na Fig. 30 e seu fluxograma pode ser visto na Fig. 31, o mesmo está descrito na seção a seguir.

Entrada: Imagem Aérea

```

IV <- calcula_indice(Imagem Aérea)
IV_normalizado <- normaliza_indice(IV)
IV_filtrado <- filtra_indice(IV_normalizado)
IV_equalizado <- equaliza_indice(IV_normalizado)
histograma <- calcula_historama(IV_equalizado)
k <- aplica_k_means(histograma)
zonas <- segmenta_zonas(IV_equalizado, k)
zonas_colorida <- mapa_de_cor(zonas, cor)

```

Saída: zonas_colorida

Figura 30 – Pseudocódigo do algoritmo




Figura 31 – Fluxograma do algoritmo

3.2 Descrição do algoritmo

O primeiro passo é fornecer uma imagem da área que se deseja analisar, a mesma deve conter os espectros de luz necessários para se calcular algum dos Índices de Vegetação (IV) implementados, no caso deste trabalho estes são o VARI e NDVI. Como explicado na seção 1.4.1 para calcular o primeiro é necessário as bandas RGB, e para o segundo é necessário os espectros NIR e o vermelho, ou NIR e o azul.

Em seguida, o Índice de Vegetação é calculado utilizando a equação correspondente aos canais de cores presentes. Devido ao formato que estas imagens são salvas e da característica das equações os resultados deste cálculo são números reais e se encontram entre -1 e 1, porém este formato dificulta a aplicação de algumas funções de processamento digital de imagens, por isso os valores devem ser convertidos para uma escala de números inteiros entre 0 e 255.

Para cada um dos índices esta normalização é realizada de maneira diferente, no caso do VARI as plantas podem retornar valores negativos, por isso soma-se 1 em cada pixel da imagem fazendo com que todos os pixels se encontrem entre 0 e 2, em seguida multiplica-se todos os valores por 128 arredondando o resultado para números inteiros. Já para o NDVI a vegetação sempre tem valor superior a 0, por essa razão não existe a necessidade de se converter os valores negativos, então aplica-se um *threshold* para zero de todos os valores inferiores a 0 resultando em uma imagem onde todos os pixels se encontram entre 0 e 1, e depois todos os valores são multiplicados por 255 e arredondados para números inteiros.

Ao analisar o resultado do cálculo do Índice de Vegetação e sua normalização (Fig. 32) foi percebido que imagem resultante apresenta bastantes descontinuidades espaciais, ou seja, ruídos. Isto é decorrente de vários fatores, como a presença de pequenos espaços entre as plantas, pequenas áreas com grande variação no índice, e até mesmo devido ao processo de discretização ao capturar as imagens.

O objetivo de se definir as regiões de características homogenias é agrupar espacialmente as áreas que possuem características semelhantes, para que então cada região possa ser tratada de maneira única. Sendo assim, pequenas regiões com altas variações em relação ao seus vizinhos não são representativas, por isso é de grande importância para o bom funcionamento do algoritmo remover os *outliers*.

Neste sentido, para remover os ruídos e suavizar o Índice de Vegetação um filtro passa-baixa é aplicado, vários diferentes tipos de filtros foram testados, como um filtro Normalizado(MCDONNELL, 1981) (Fig. 33), um filtro Gaussiano(LEE, 1983) (Fig. 34) e um filtro Mediano(GALLAGHER; WISE, 1981) (Fig. 35).

Ao fim desta etapa, geralmente, os valores de intensidade do Índice de Vegetação não ficam bem distribuídos ao longo de todos os possíveis valores (0-255), o que resulta em




Figura 32 – NDVI




Figura 33 – NDVI com filtro normalizado




Figura 34 – NDVI com filtro gaussiano




Figura 35 – NDVI com filtro mediano

uma dificuldade de distinguir variações no IV da lavoura devido a esta pequena diferença. Consequentemente, a classificação das regiões de características homogêneas pelo algoritmo falha.

Então, para resolver este problema a imagem é equalizada aumentando o seu contraste e melhor distribuindo os valores de intensidade, e com isso possibilitando a classificação das regiões.

O problema de classificação de ZM pode ser atacado de diversas maneiras como pode ser visto na seção ??, porém neste trabalho foi escolhido explorar uma nova abordagem. Para isto, tem-se um interesse em investigar um recurso de remapeamento de espaço, uma vez que a definição de regiões de características homogêneas pode ser considerada um difícil problema de segmentação. Isto se deve ao fato da possibilidade de uma ZM aparecer em mais de uma área da plantação e estas serem espacialmente desconectadas. Sendo assim, ao realizar uma mudança de espaço esta dificuldade pode ser superada.

Para realizar este remapeamento o histograma da imagem é calculado e utilizado como novo espaço de busca, isto é vantajoso pois reduz o dimensionamento dos dados, simplificando assim a complexidade dos passos seguintes desta metodologia, além de diminuir o custo computacional para realizar a segmentação.

Uma vez que o histograma é calculado, o problema torna-se uma linearização em várias escalas, pois é usual buscar mais de duas ZM. Mas, infelizmente este problema ainda é complicado por um número de fatores externos, como variações de iluminação ao longo da captura das imagens e das condições climáticas variáveis.

Em problemas de linearização em várias escalas as técnicas de agrupamento apresentam um bom desempenho, uma vez que a mecânica do algoritmo consegue decidir

naturalmente o centroide mais adequado para cada um dos segmentos desejados. Visto que o número de grupos não é um problema neste caso, o algoritmo *K-means* (CHEN; CHEN; CHIEN, 2008) é apresentado como uma alternativa estável, eficiente e bem conhecida.

Então, com um numero de ZM desejadas (n) servido como entrada para o algoritmo aplica-se o *K-means* no histograma, e como saída do tem-se n valores que representam o centroide de cada segmento.

Em seguida, é analisado a intensidade de cada pixel da imagem e classifica-se cada ponto como pertencente a um dos segmentos classificados. A categoria na qual o pixel será inserido é escolhida pela menor diferença entre o valor de intensidade do mesmo e do centroide de cada um dos grupos identificados.

É importante enfatizar que n pode ser interpretado como o número de ZM na imagem de saída, e também que esse parâmetro é definido pelo usuário. Entretanto, na prática, o número de regiões de características homogêneas não é maior que 5, por isso recomenda-se limitar o valor deste parâmetro em 5.

Por fim, tem-se como resultado dos passos anteriores uma imagem com as ZM definidas, como a imagem possui apenas 1 canal a mesma é em escala de cinza. Porém, este resultado é utilizado para mostrar ao fazendeiro as ZM presentes na área analisada, por isso é necessário que os resultados sejam intuitivos e fáceis de serem interpretados.

Por esta razão, colore-se a imagem resultante aplicando um mapa de cor que varia entre um vermelho escuro, representa valores com IV baixo, e um verde escuro, representam valores de IV altos.

3.3 Resultados secundários

Além das ZM, foi implementado o cálculo de outros resultados para agregar mais valor ao produtor, sendo eles o Índice de Vegetação colorido e o Grid. O primeiro nada mais é do que a aplicação do mesmo mapa de cor utilizado nas ZM no IV, isto é feito para facilitar a visualização da diferença do IV ao longo da lavoura.

Já o *Grid* pode ser interpretado como um abaixamento na resolução do IV, para isto a imagem é dividida em inúmeros retângulos, de tamanho definido pelo usuário, e cada um destes passa a ter o valor da média dos pixels contidos nele. Por fim, assim como as ZM e IV o Grid é colorido com o mesmo mapa de cores.

Por exemplo, na matriz representada na Fig. 36 cada pixel tem um lado de L metros, um resultado de *Grid* com tamanho $2L \times 2L$ metros para esta mesma imagem pode ser visto na Fig. 37.




Figura 36 – Matriz IV




Figura 37 – Grid da Fig. 36

4 Resultados e Discussões

4.1 Configurações

Para capturar as imagens aéreas da plantação o VANT sx2 (Fig. 29) foi utilizado, quando está em voo capturando as imagens o mesmo voa em uma altitude entre 100 e 150 metros, sua velocidade em relação ao ar deve ser de no mínimo 10 metros por segundo para garantir sua sustentação, idealmente $15m/s$ garantindo um voo estável, e a velocidade em relação ao solo não deve exceder $15m/s$, pois velocidades altas capturariam imagens mais distantes espacialmente.

O VANT é totalmente autônomo e consegue voar sem recarregar sua bateria entre 1 hora e 1 hora e meia, o plano de voo do avião é configurado antes da decolagem de forma que a aeronave sobrevoe a área a ser analisada e capture uma fotografia a cada 2 segundos.

O sensor (câmera) utilizado para captura das fotos utilizadas neste trabalho foi uma Canon S110 (Fig. 25). Originalmente este equipamento consegue capturar apenas os espectros do vermelho, verde e azul (RGB), possibilitando assim o cálculo do VARI. Entretanto, para realizar o cálculo do NDVI a banda do Infra Vermelho Próximo (NIR) é necessária. Por isso, o filtro óptico da mesma foi trocado por um que permite a percepção do canal NIR, resultando na captura de imagens compostas pelas bandas NIR, verde e azul (NIRGB).

4.2 Pré Processamento

Como explicado anteriormente o VANT é configurado para capturar várias imagens aéreas da área que será analisada. Porém, caso o algoritmo desenvolvido fosse utilizado diretamente com essas imagens o processo seria bastante custoso computacionalmente, uma vez que o mesmo teria que processar várias imagens, além de apresentar erros devidos a distorção destas imagens causadas pela inclinação do VANT e da distorção inerente da lente da câmera.

Por isso, após todas as imagens terem sido capturadas é necessário agrupá-las em apenas uma grande imagem que representa toda a área que será analisada, além de corrigir a distorção de cada uma destas imagens. Este processo é chamado de ortomosaicagem (CAPEL, 2004), e para isto um *software open-source* chamado *OpenDroneMap* foi utilizado.

Então, a saída deste processo é uma grande imagem da lavoura que é chamado de ortomosaico, um exemplo contendo os canais NIRGB pode ser visto na Fig. 38.




Figura 38 – Ortomosaico NIRGB

Pode-se perceber que o mesmo contém áreas que estão fora da região que se deseja analisar, por exemplo a mata nativa no canto superior direito da imagem.

Por isso, foi desenvolvida uma ferramenta para recortar (Fig. 39) a região que se tem interesse em processar, e a mesma foi integrada em uma plataforma web cujo maior objetivo é permitir a visualização e manipulação dos resultados.

Com isso, o ortomosaico recortado (Fig. 40) é utilizado como entrada para o algoritmo apresentado na Metodologia (Fig. 31).



Figura 39 – Recortando o ortomosaico



Figura 40 – Ortomosaico Recortado

4.3 Aplicação do algoritmo

Utilizando o ortomosaico recortado (Fig. 40) como entrada do algoritmo e aplicando os dois passos seguintes, lembrando que devido a imagem conter os canais NIRGB o Índice de Vegetação calculado é o NDVI, temos como saída a imagem mostrada na Fig. 41.

Uma vez que o IV é calculado e normalizado ele é utilizado para gerar 3 resultados distintos, sendo eles o Índice Colorido, o *Grid* e as ZM.

Para o primeiro é necessário apenas aplicar um mapa de cor na imagem em escala de cinza, o mapa resultante deste processo pode ser visualizado na Fig. 42

A escala de cores utilizada neste caso varia de um tom de vermelho passando por um amarelo até chegar em um verde, este mapa de cor será utilizado posteriormente nos outros mapas resultantes.

Para gerar o *Grid* foi realizado o processo redução de resolução explicado na Metodologia, foi utilizado o tamanho de cada quadrado de 30x30m, e então aplicou-se o mapa de cor e seu o resultado está exibido na Fig. 43



Figura 41 – NDVI



Figura 42 – NDVI Colorido



Figura 43 – Grid 30x30m

Já para a definição das ZM é necessário alguns passos extras, o primeiro deles é aplicar um filtro com o intuito de suavizar a imagem, sendo assim um filtro mediano com tamanho de 100 pixels foi aplicado e se resultado pode ser visto na Fig. 44.

Em seguida, é preciso realizar uma equalização na imagem suavizada a fim de aumentar o contraste da mesma. A imagem resultante deste processo está indicada na Fig. 45.

A motivação para esta etapa pode ser facilmente percebida analisando os histogramas das imagens pré e pós equalização. No primeiro caso (Fig. 46) percebe-se que a ocorrência das intensidades luminosas estão concentradas na região central, já no segundo caso (Fig. 47) nota-se que os pixels da imagem foram melhores distribuídos ao longo da intensidade luminosa.

Após a equalização o passo seguinte é a aplicação do algoritmo *K-means* no histograma da imagem filtrada e equalizada (Fig. 47). Neste trabalho o algoritmo foi configurado de forma que os centros são iniciados igualmente espaçados e cobrindo todo o espaço de busca (0-255). Com isso, adotando o número de Zonas de Manejos igual a 5, os grupos foram inicializados com os valores {0, 63, 127, 191, 255}, como pode ser visto na Fig. 48. Após algumas iterações o resultado obtido foi {13, 58, 120, 213, 244}, o mesmo pode ser observado na Fig. 49.




Figura 44 – NDVI com filtro mediano 100




Figura 45 – NDVI equalizado com filtro mediano 100




Figura 46 – Histograma da Fig. 44






Figura 47 – Histograma da Fig. 45

Figura 48 – Grupos iniciais do *K-means*Figura 49 – Grupos finais do *K-means*

Com os grupos encontrados e os dados classificados aplica-se o mesmo mapa de cor utilizado no NDVI e Grid, resultando no mapa da Fig. 50.

4.4 Importância dos Passos

Com a intenção de mostrar a importância dos passos de equalização e aplicação do filtro, os resultados serão mostrados com algumas alterações nestas etapas.

Primeiramente, os passos de aplicação do filtro e equalização são ignorados, de forma que as Zonas de Manejo são calculadas diretamente no Índice de Vegetação.

Quando o algoritmo é executado desta maneira, com o número de zonas igual 5,



Figura 50 – Zonas de Manejo com filtro mediano de tamanho 100

é possível perceber ao analisar o resultado exibido na Fig. 51 que o mesmo não obtém sucesso em classificar as diferentes ZM.

Em seguida, com apenas a etapa da aplicação filtro ignorada e mantendo o número de zonas igual a 5 obtém-se o resultado mostrado na Fig. 52. É percebido que o algoritmo conseguiu agrupar um pouco mais os dados, porém o resultado ainda não é satisfatório uma vez que o algoritmo não conseguiu classificar 5 regiões diferentes, além de que as zonas encontradas não estão claramente definidas, ou seja, apresentam bastante descontinuidades.



Figura 51 – ZM sem filtro e equalização



Figura 52 – ZM sem filtro

Sendo assim, pode-se concluir que as etapas de aplicação do filtro e da equalização são necessárias para obtenção de bons resultados.

Para evidenciar mais ainda o efeito do filtro, o resultado da aplicação de diferentes tipos de filtro com tamanhos variáveis estão mostrados nas Fig. 53 - Fig. 56.

Nestes resultados é perceptível que o algoritmo teve sucesso em classificar 5 zonas



Figura 53 – ZM - filtro mediano 50



Figura 54 – ZM - filtro mediano 100



Figura 55 – ZM - filtro normalizado 100



Figura 56 – ZM - filtro gaussiano 100

distintas, entretanto apesar de parecerem satisfatórios é necessário realizar uma validação dos resultados obtidos. Tal validação torna-se extremamente dispendiosa se for necessário confrontar as imagens com as análises da região representada, tais como: objetivos de solo, índice de produtividade, entre outros.

Diante da complexidade e do pouco tempo disponível, dado a natureza deste trabalho, a maneira encontrada para validar as ZM calculadas foi através da confrontação dos resultados obtidos com a opinião de um especialista na área. Com isso, este trabalho foi mostrado para alguns agrônomos com experiência na determinação de ZM, e por meio da avaliação deles este trabalho foi validado.

4.5 Estudo de caso de mapeamentos utilizando o NDVI

Esta seção contém alguns exemplos de plantações que foram analisadas através do NDVI, utilizando o algoritmo desenvolvido. Os mapas provenientes do *software* foram levados em campo e auxiliaram na identificação de reboleiras, problemas no solo, falhas nutricionais, doenças e pragas.

O ortomosaico mostrado na Fig. 57 foi capturado no dia 1 de dezembro de 2017 na Bahia e é referente a uma plantação de soja, e possui uma área de 144ha. Os seus resultados de NDVI, ZM e *Grid*, podem ser vistos nas Fig. 58, 59 e 60, respectivamente. As ZM foram geradas utilizando o filtro mediano com tamanho de 150 pixels, e o grid com cada quadrado de 30x30m.



Figura 57 – Ortomosaico de soja em 01/12/2017 na Bahia




Figura 58 – NDVI de soja




Figura 59 – ZM de Soja



Figura 60 – Grid de Soja

É possível perceber que os 3 mapas estão relacionados e são condizentes com o que era esperado. Percebe-se que as ZM foram classificadas com sucesso, porém ainda

apresentam pequenas zonas que poderiam ter sido eliminadas por um borramento maior.

Com estes resultados em mãos os produtores foram até a lavoura e analisaram os motivos da variação do NDVI. Primeiramente, eles validaram que algumas áreas estavam realmente com um vigor bastante diferente (Fig. 61).

Em seguida, guiados pelos mapas fizeram algumas amostras de solo que vieram a identificar a presença de nematoides (Fig. 62). Depois, perceberam que algumas regiões apresentavam alto vigor devido a plantação de linhas duplas (Fig. 63), e por fim verificaram que algumas regiões com baixa vitalidade eram devido a estradas antigas que compactaram o solo (Fig. 64).




Figura 61 – Variação de vigor na soja

Um outro exemplo de estudo de caso, realizado em uma plantação de milho, através do NDVI pode ser visto na Fig. 65. Neste caso foi possível identificar problemas causados por cascalho no solo, tronco de árvores tombados, nematoides e devido a ataques de lagartas.




Figura 62 – Nematoides na soja




Figura 63 – Linhas duplas na soja




Figura 64 – Manchas de solo na soja




Figura 65 – NDVI de uma plantação de milho

Conclusão

A definição de ZM em uma lavoura é uma tarefa de considerável importância no processo de manejo de uma lavoura, uma vez que estas auxiliam o produtor a decidir o quanto de cuidado cada região da plantação necessita, permitindo ajustar adequadamente a quantidade de insumo aplicado em cada região, além de conseguir fazer coletas de solo e folhas de maneira mais direcionada para cada ZM, e como resultado gerar um aumento na produtividade e uma diminuição no custo por hectare da lavoura.

Apesar da grande importância da definição de ZM os métodos atuais utilizados para gerar e validar as mesmas são bastante subjetivos, por isso existe uma necessidade para o desenvolvimento de metodologias mais ágeis e cientificamente comprovadas para geração das mesmas.

Em vista disto, este trabalho teve como objetivo principal desenvolver uma metodologia bem definida para delinear as ZM a partir de imagens aéreas da lavoura. Porém, durante o desenvolvimento do mesmo várias dificuldades foram encontradas, como a pequena quantidade de referências na literatura, a escolha de um algoritmo de agrupamento, a percepção da necessidade da aplicação da equalização e de um filtro, a escolha de qual filtro utilizar, e ainda a verificação da qualidade dos resultados.

Como estratégia para definição das ZM a partir de uma imagem digital, optou-se por trabalhar com técnicas de agrupamento de dados. Desta forma, o primeiro desafio foi decidir qual algoritmo de agrupamento utilizar, para solucionar esta questão o K-means se mostrou, ainda que simples, um algoritmo bastante robusto.

Em seguida, ao aplicar o *K-means* no histograma da imagem do Índice de Vegetação o mesmo não foi capaz de classificar o número de zonas desejado, ao analisar o histograma foi percebido que o mesmo estava pouco distribuído e isto poderia ser uma das causas da falha na classificação. Com isso, a etapa de equalização foi incluída no algoritmo a fim de tentar solucionar o problema.

Com a inclusão desta etapa foi percebido que as ZM ficaram mais agrupadas, porém ainda apresentavam bastante descontinuidades. Então, com o intuito de diminuir a presença de descontinuidades optou-se pela aplicação de um filtro passa-baixo, e assim três tipos de filtros distintos foram testados, sendo eles, o Normalizado, o Mediano e o Gaussiano.

Após inúmeros testes, concluiu-se que tais descontinuidades se tornavam menos presentes a medida que se aumentava o tamanho do filtro utilizado, dando a impressão que a partir de um limiar de tamanho o algoritmo conseguia classificar as ZM. Porém, devido a

falta de metodologias bem definidas para determinação destas ZM, de outra forma, existiu uma grande dificuldade em validar os resultados obtidos.

Diante da complexidade e do pouco tempo disponível, dado a natureza deste trabalho, a maneira encontrada para validar as ZM calculadas foi através da confrontação dos resultados obtidos com a opinião de um especialista na área. Com isso, os resultados foram submetidos a validação visual de especialistas com experiência na determinação de ZM, e de acordo com a opinião destes os resultados foram aprovados.

É importante destacar que algoritmo desenvolvido neste trabalho já é utilizado pela empresa Sensix Inovações em Drones LTDA. para fornecer resultados para inúmeros clientes, tendo processado aproximadamente 40 mil hectares durante o período de outubro de 2017 e janeiro de 2018. Com isso, uma vez que a grande maioria dos clientes desta empresa são agrônomos que possuem experiência na área, e todos tem apresentado boa aceitação dos resultados fornecidos, o trabalho ganha mais força e credibilidade.

Entretanto, ainda existe a necessidade da continuação deste trabalho na busca de testes que possam validar os resultados de maneira científica, um ponto de partida recomendado seria a comparação das ZM com mapas de análise de solo e folhas, mapas de textura, produtividade, umidade e condutividade elétrica do solo.

Outro aspecto que ainda deve ser explorado de maneira mais profunda é a escolha do *K-means* para classificar as ZM, de forma que, como trabalho futuro outros algoritmos de agrupamento devem ser testados e comparados.

Embora, a definição das Zonas de Manejo utilizando o algoritmo proposto não tenha sido validada com algum método científico, o trabalho foi aceito pela comunidade acadêmica através de uma publicação no XIII Workshop de Visão Computacional realizado em Natal-RN no ano de 2017 ([SILVA; ESCARPINATI; ABDALA, 2017](#)).

Referências

- ALVES RICARDO VICENTE FERREIRA, R. B. d. A. G. M. O. Otimização da identificação de falhas de plantio na cana-de-açúcar com uso de geoprocessamento. *Anais do X Congresso Brasileiro de AgroInformática*, 2015. Citado na página 11.
- BASSO, B. et al. Spatial validation of crop models for precision agriculture. *Agricultural Systems*, Elsevier, v. 68, n. 2, p. 97–112, 2001. Citado na página 11.
- BONGIOVANNI, R.; LOWENBERG-DEBOER, J. Precision agriculture and sustainability. *Precision agriculture*, Springer, v. 5, n. 4, p. 359–387, 2004. Citado na página 11.
- CAMPBELL, J. B.; WYNNE, R. H. *Introduction to remote sensing*. [S.l.]: Guilford Press, 2011. Citado na página 25.
- CAPEL, D. Image mosaicing. In: *Image Mosaicing and Super-resolution*. [S.l.]: Springer, 2004. p. 47–79. Citado na página 35.
- CHEN, T.-W.; CHEN, Y.-L.; CHIEN, S.-Y. Fast image segmentation based on k-means clustering with histograms in hsv color space. In: IEEE. *Multimedia Signal Processing, 2008 IEEE 10th Workshop on*. [S.l.], 2008. p. 322–325. Citado na página 33.
- CID-GARCIA, N. M. et al. Rectangular shape management zone delineation using integer linear programming. *Computers and electronics in agriculture*, Elsevier, v. 93, p. 1–9, 2013. Citado na página 29.
- DYER, S. A. *Wiley survey of instrumentation and measurement*. [S.l.]: John Wiley & Sons, 2004. Citado na página 25.
- FILHO, O. M.; NETO, H. V. *Processamento digital de imagens*. [S.l.]: Brasport, 1999. Citado 4 vezes nas páginas 13, 14, 18 e 19.
- GALLAGHER, N.; WISE, G. A theoretical analysis of the properties of median filters. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, IEEE, v. 29, n. 6, p. 1136–1141, 1981. Citado 2 vezes nas páginas 14 e 31.
- GITELSON, A. A. et al. Novel algorithms for remote estimation of vegetation fraction. *Remote sensing of Environment*, Elsevier, v. 80, n. 1, p. 76–87, 2002. Citado na página 23.
- HONKAVAARA, E. et al. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight uav spectral camera for precision agriculture. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 5, n. 10, p. 5006–5039, 2013. Citado na página 11.
- HUETE, A. et al. Overview of the radiometric and biophysical performance of the modis vegetation indices. *Remote Sensing of Environment*, v. 83, n. 1, p. 195 – 213, 2002. ISSN 0034-4257. The Moderate Resolution Imaging Spectroradiometer (MODIS): a new generation of Land Surface Monitoring. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425702000962>>. Citado na página 23.

- HUETE, A. R. A soil-adjusted vegetation index (savi). *Remote sensing of environment*, Elsevier, v. 25, n. 3, p. 295–309, 1988. Citado na página 23.
- JAIN, A. K. Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, v. 31, n. 8, p. 651 – 666, 2010. ISSN 0167-8655. Award winning papers from the 19th International Conference on Pattern Recognition (ICPR). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865509002323>>. Citado na página 21.
- KAUFMAN, Y. J.; TANRE, D. Atmospherically resistant vegetation index (arvi) for eos-modis. *IEEE transactions on Geoscience and Remote Sensing*, IEEE, v. 30, n. 2, p. 261–270, 1992. Citado na página 23.
- LEE, J.-S. Digital image smoothing and the sigma filter. *Computer vision, graphics, and image processing*, Elsevier, v. 24, n. 2, p. 255–269, 1983. Citado 2 vezes nas páginas 14 e 31.
- LI, Y. et al. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. *Computers and Electronics in Agriculture*, Elsevier, v. 56, n. 2, p. 174–186, 2007. Citado na página 28.
- MCDONNELL, M. Box-filtering techniques. *Computer Graphics and Image Processing*, Elsevier, v. 17, n. 1, p. 65–70, 1981. Citado 2 vezes nas páginas 14 e 31.
- MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. *Agricultura de precisão*. [S.l.]: Oficina de Textos, 2015. Citado na página 23.
- NASA. *Moderate Resolution Imaging Spectroradiometer*. 2017. Disponível em: <<https://terra.nasa.gov/about/terra-instruments/modis>>. Citado na página 25.
- NAVARRO ALISSON GARCIA, L. G. R. A. S. J. M. S. M. G. V. J. D. Índices de vegetação para imagens capturadas por veículos aéreos não tripulados. *Anais do X Congresso Brasileiro de AgroInformática*, 2015. Citado 2 vezes nas páginas 11 e 26.
- PEDROSO, M. et al. A segmentation algorithm for the delineation of agricultural management zones. *Computers and Electronics in Agriculture*, Elsevier, v. 70, n. 1, p. 199–208, 2010. Citado 2 vezes nas páginas 28 e 29.
- PRIMICERIO, J. et al. A flexible unmanned aerial vehicle for precision agriculture. *Precision Agriculture*, Springer, v. 13, n. 4, p. 517–523, 2012. Citado na página 26.
- ROUDIER, P. et al. Management zone delineation using a modified watershed algorithm. *Precision Agriculture*, Springer, v. 9, n. 5, p. 233, 2008. Citado na página 29.
- RUSS, G.; KRUSE, R. Exploratory hierarchical clustering for management zone delineation in precision agriculture. In: SPRINGER. *Industrial Conference on Data Mining*. [S.l.], 2011. p. 161–173. Citado na página 29.
- SILVA, G.; ESCARPINATI, M. C.; ABDALA, D. Definition of management zones through image processing for precision agriculture. In: *WVC 2017 ()*. [s.n.], 2017. Disponível em: <<http://XXXXX/175530.pdf>>. Citado na página 46.

- TEAL, R. et al. In-season prediction of corn grain yield potential using normalized difference vegetation index. *Agronomy Journal*, American Society of Agronomy, v. 98, n. 6, p. 1488–1494, 2006. Citado 2 vezes nas páginas 11 e 24.
- TRIPICCHIO, P. et al. Towards smart farming and sustainable agriculture with drones. In: IEEE. *Intelligent Environments (IE), 2015 International Conference on*. [S.l.], 2015. p. 140–143. Citado na página 11.
- USGS. *Landsat Project*. 2017. Disponível em: <<https://landsat.usgs.gov/about-landsat>>. Citado na página 25.
- ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision agriculture*, Springer, v. 13, n. 6, p. 693–712, 2012. Citado 3 vezes nas páginas 11, 23 e 26.