

Guilherme Afonso Soares

Identificação de linhas de plantio por meio da Transformada de Hough

Uberlândia, Brasil

2017

Guilherme Afonso Soares

Identificação de linhas de plantio por meio da Transformada de Hough

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Sistemas de Informação.

Universidade Federal de Uberlândia - UFU

Faculdade de Computação

Bacharelado em Sistemas de Informação

Orientador: Prof. Mauricio Cunha Escarpinati

Uberlândia, Brasil

2017

Guilherme Afonso Soares

Identificação de linhas de plantio por meio da Transformada de Hough

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Sistemas de Informação.

Trabalho aprovado. Uberlândia, Brasil, 03 de agosto de 2017:

Prof. Mauricio Cunha Escarpinati
Orientador

Prof. Daniel Duarte Abdala
Convidado 1

Prof^a. Elaine Ribeiro de Faria Paiva
Convidado 2

Uberlândia, Brasil
2017

Agradecimentos

Aos meus pais e irmãos, pelo apoio incondicional e pelo incentivo a galgar objetivos cada vez maiores.

À esta universidade e seu corpo docente, por todo o conhecimento que me permitiram adquirir.

Ao Professor Mauricio Cunha Escarpinati, meu orientador e, acima de tudo, um grande amigo que colaborou não somente para a execução deste trabalho mas que também, durante todo o período da graduação, fez o possível para me motivar e fazer com que eu descobrisse as possibilidades da computação e da ciência.

Aos meus amigos e colegas, que colaboraram para transformar a experiência da graduação em algo único e inesquecível.

À todos que de alguma forma colaboraram para que eu alcançasse esse objetivo, meu muito obrigado.

Resumo

Um grande desafio na agricultura de precisão se refere à detecção de linhas de plantio em imagens digitais obtidas por VANTs (Veículos Aéreos Não Tripulados), já que a partir disso é possível estimar a produtividade de uma lavoura, realizar a contagem de plantas, dentre outras atividades. Entretanto, é inviável que isso seja feito de forma manual, já que se trata de uma atividade dispendiosa. Diversos autores propuseram técnicas para realizar a tarefa, porém, por vezes existe a necessidade de um conhecimento prévio ou de imagens com alta resolução espacial para execução satisfatória, o que nem sempre é possível. O método proposto neste trabalho faz a detecção dessas linhas utilizando técnicas de segmentação de imagens, mais especificamente a Transformada de Hough. Para aprimorar o desempenho da transformada, uma técnica de processamento particionado e uma de redução de artefatos indesejados foram propostas. Foi possível obter bons resultados mesmo em situações onde há diferenças de luminosidade e falhas na linha de plantio.

Palavras-chave: agricultura de precisão; transformada de Hough; e visão computacional.

Lista de ilustrações

Figura 1 – Etapas de um sistema de visão computacional	11
Figura 2 – Demonstração dos valores dos pixels de uma imagem digital	12
Figura 3 – Sistema de transmissão Bartlane	13
Figura 4 – Espectro eletromagnético	13
Figura 5 – Comparação de imagem de sensor CMOS e CCD	14
Figura 6 – Primeira imagem obtida através de tomografia computadorizada	15
Figura 7 – Os três tipos de vizinhança de pixel	16
Figura 8 – Definição de limiares em histogramas	17
Figura 9 – Máscara para detecção de pontos	18
Figura 10 – Diferentes máscaras para detecção de linhas	18
Figura 11 – Exemplo do realce de bordas com os operadores de Sobel e Prewitt	19
Figura 12 – Operadores verticais e horizontais de Sobel e Prewitt	19
Figura 13 – Diferentes elementos estruturantes	20
Figura 14 – Exemplo do processo de erosão	21
Figura 15 – Exemplo do processo de dilatação	21
Figura 16 – Exemplo do processo de fechamento	22
Figura 17 – Exemplo do processo de esqueletização	22
Figura 18 – Exemplo da operação de poda	23
Figura 19 – Demonstração dos parâmetros que descrevem uma reta	23
Figura 20 – Exemplos de falhas recorrentes em imagens aéreas de lavouras	31
Figura 21 – Processo de segmentação	33
Figura 22 – Demonstração de uma curva numa linha de plantio	33
Figura 23 – Resultado do janelamento	34
Figura 24 – Resultado do janelamento sobreposto	35
Figura 25 – Demonstração da aplicação do método de remoção de ruído	35
Figura 26 – Imagens utilizadas nos testes preliminares do método	37
Figura 27 – Resultado da demarcação manual das linhas de plantio das imagens utilizadas no conjunto inicial de testes	38
Figura 28 – Demarcação do acerto na imagem detectada	38
Figura 29 – Comportamento da taxa de acerto a partir do isolamento dos parâmetros	40
Figura 30 – Imagens utilizadas na segunda fase de testes	41

Lista de tabelas

Tabela 1 – Conjunto dos valores utilizados para os parâmetros de teste	37
Tabela 2 – Distribuição dos resultados para o conjunto de testes inicial	39
Tabela 3 – Resultados da segunda fase de processamento	41

Sumário

	Introdução	8
1	CONCEITOS ADOTADOS	11
1.1	Visão computacional	11
1.1.1	Imagem	12
1.1.2	Aquisição de imagens	12
1.1.3	Processamento digital de imagens	14
1.1.3.1	Vizinhança e Conectividade	15
1.1.3.2	Segmentação de Imagens	16
1.1.3.2.1	Limiarização	16
1.1.3.2.2	Detecção de pontos e linhas	17
1.1.3.2.3	Detecção de bordas	18
1.1.3.2.4	Crescimento de região	19
1.1.3.3	Morfologia matemática	19
1.1.3.3.1	Elemento estruturante	20
1.1.3.3.2	Erosão	20
1.1.3.3.3	Dilatação	21
1.1.3.3.4	Fechamento	21
1.1.3.3.5	Esqueletização	22
1.1.3.3.6	Poda	22
1.1.3.3.7	Transformada de Hough	23
1.2	Agricultura de precisão	24
1.2.1	Veículos Aéreos Não-Tripulados	25
2	TRABALHOS CORRELATOS	27
2.1	Ramesh et. al., 2016	27
2.2	Pérez-Ortiz et. al., 2015	28
2.3	Guerrero et. al., 2013	29
3	METODOLOGIA	31
4	RESULTADOS	37
5	CONCLUSÃO	42
	REFERÊNCIAS	44

Introdução

A agricultura é um campo em constante desenvolvimento. Desde os primórdios da humanidade a terra é utilizada para produção de alimentos, por meio do emprego de técnicas que se aperfeiçoam com o passar do tempo. Com o contínuo crescimento populacional e a constante disputa por espaço, é fundamental que se consiga extrair o máximo da capacidade da terra, evitando desabastecimento e aumento no custo dos alimentos. Pensando neste tipo de problema, nas últimas décadas foram desenvolvidas técnicas com foco no aumento de produtividade na agricultura, como a utilização de implementos cada vez mais modernos e o desenvolvimento de novos tipos de defensivos agrícolas e sementes transgênicas, que proporcionam à planta uma maior resistência a pragas e doenças e, conseqüentemente, ampliam a capacidade de produção (CARVALHO, 2011).

Um novo campo de avanço na agricultura está no emprego de tecnologias de precisão no manejo da lavoura, com a utilização de recursos de tecnologia da informação para gestão dos processos e emprego de técnicas de georeferenciamento, que possibilitam o monitoramento constante e mais preciso da cultura. Conhecida como Agricultura de precisão, tal segmento tem sido fortalecido desde meados da década de 1990.

A agricultura de precisão (PIERCE; NOWAK, 1999) fornece um conjunto de técnicas que possibilita a detecção de possíveis problemas no plantio, servindo-se de tecnologias como imagens via satélite e do Sistema de Posicionamento Global (GPS, do inglês, *Global Positioning System*), além de Sistemas de Informação Geográfica (SIG).

No fim da década de 1990, com a difusão de pesquisas de novos métodos na área de Visão Computacional, vislumbrou-se a possibilidade de aplicação destas técnicas na agricultura de precisão (TILLET, 1991). Este novo conjunto de ferramentas permitiu um monitoramento ainda mais eficaz do desempenho das lavouras. Por meio da utilização de Veículos Aéreos Não-Tripulados (VANTs, popularmente conhecidos como *drones*), de sensores de várias frequências do espectro eletromagnético, e das novas possibilidades trazidas pela pesquisa científica (HERWITZ et al., 2004), o acompanhamento da lavoura se tornou uma tarefa menos dispendiosa e menos dependente do acompanhamento presencial.

Algumas frentes da pesquisa de técnicas de processamento digital de imagens na agricultura buscam a mensuração de nutrientes das plantas, acompanhamento de irrigação (MERON et al., 2010), análise de plantio (JI; QI, 2011), identificação e classificação de pragas (WEN; ZHU, 2010), doenças (SANKARAN et al., 2010) e ervas daninhas (LÓPEZ-GRANADOS, 2011), estimativa de produção (PAYNE et al., 2013), dentre outras.

Especificamente no que tange a análise de plantio, uma grande dificuldade está na

identificação das efetivas linhas de plantio (JI; QI, 2011). Tal informação é de extrema importância pois dela depende o sucesso de tarefas como: contagem de plantas; estimativa de produtividade; detecção de falhas no plantio, etc. Desta forma, este trabalho propõe um método computacional que, a partir das imagens digitais fornecidas pelos VANTs, realize de forma automática a detecção de linhas de plantio em imagens de baixa-média altitude. Para tanto serão empregadas técnica de processamento digital de imagens e visão computacional a fim de se obter tais resultados.

Objetivos

Nesta seção serão descritos os principais objetivos deste trabalho que serão apresentados de forma geral e específica.

Objetivos Gerais

Propor um método de detecção de linhas de plantio em imagens obtidas por meio de Veículos Aéreos Não-Tripulados fazendo uso da Transformada de Hough e técnicas de segmentação de imagens e morfologia matemática.

Objetivos Específicos

- Realizar um estudo das técnicas de segmentação de imagens e morfologia matemática e seus efeitos e aplicações em Visão Computacional
- Entender o funcionamento da Transformada de Hough para detecção de segmentos de reta
- Aprimorar o conhecimento em técnicas de manipulação de imagens para pesquisa científica
- Compreender a metodologia da pesquisa científica
- Desenvolver o senso crítico para analisar resultados de trabalhos científicos
- Empregar conhecimentos matemáticos e computacionais em aplicações reais

Justificativa

A tarefa de detecção de linhas de plantio em lavouras, a partir de imagens aéreas obtidas por VANTs, é de grande utilidade para diversas atividades no que tange o acompanhamento de uma cultura, em especial sob seu aspecto econômico. Devido ao

grande volume de dados representado por esse tipo de imagem, a execução manual se torna extremamente dispendiosa e, portanto, inviável.

Diversos autores buscam o desenvolvimento de métodos computacionais para tal, porém os resultados por vezes são eficientes apenas em situações específicas, sem presença de ervas daninhas, interrupção de linhas de plantio e diferenças de luminosidade. Dentro deste contexto, se apresentam totalmente justificados os esforços e estudos para o desenvolvimento de métodos computacionais que busquem automatizar tal processo de modo que sejam robustos e invariantes às condições adversas de aquisição da imagem, tal qual, intempéries climáticas, irregularidades do solo, entre outras comumente encontradas em aplicações reais.

O trabalho está organizado da seguinte forma: no Capítulo 1 são apresentados os conhecimentos que foram adotados durante o desenvolvimento deste trabalho; no Capítulo 2 são descritos alguns trabalhos correlatos e suas abordagens na resolução do problema de detecção de linhas de plantio; no Capítulo 3, é exposto o método desenvolvido neste trabalho para tratar o assunto; por fim, no Capítulo 4 são discutidos os resultados obtidos com este trabalho.

1 Conceitos adotados

Neste capítulo serão descritos os principais conceitos que foram aplicados no desenvolvimento deste trabalho. De início serão apresentadas as definições da área de Visão Computacional, tema central desse trabalho, dando ênfase as suas principais técnicas e, em especial à área de Processamento Digital de Imagens. Feito tal introdução o conceito de agricultura de precisão será descrito a fim de contextualizar o ambiente de aplicação deste trabalho.

1.1 Visão computacional

A área de visão computacional trata da obtenção, processamento e análise de imagens de cenários reais registrados em uma fotografia digital, a fim de gerar conhecimento para apoiar na tomada de decisão ([SHAPIRO; STOCKMAN, 2000](#)). De modo geral, o que essa linha de pesquisa busca é o desenvolvimento de técnicas e algoritmos que possam dotar um equipamento digital da capacidade de visão humana e então melhorá-la. Para entender mais profundamente o conceito de visão computacional, é necessário compreender os diferentes temas que o compõem. Na Figura 1 são demonstradas as etapas seguidas por um sistema de visão computacional.




Figura 1 – Etapas de um sistema de visão computacional ([FILHO; NETO, 1999](#))

Estas etapas estão descritas nos próximos tópicos.

1.1.1 Imagem

Uma imagem pode ser definida como uma função bidimensional cujo valor representa o produto da iluminância pela reflectância em determinado local da imagem (FILHO; NETO, 1999). Uma imagem digital é composta por elementos chamados de pontos ou pixels, distribuídos no formato de uma matriz de tamanho $x * y$. Diferentemente da imagem analógica, numa imagem digital os valores da função são finitos e discretos (GONZALEZ; WOODS, 2010). Na Figura 2 é feita uma representação dos valores dos pixels numa imagem em escala de cinza com 256 níveis.




Figura 2 – Demonstração dos valores dos pixels de uma imagem digital¹

Os primeiros registros da adoção de imagens digitais datam da década de 1920. Através de um sistema de transmissão por telegrafia desenvolvido por Harry G. Bartholomew e Maynard D. McFarlane, chamado de sistema Bartlane, era possível enviar imagens a longas distâncias por meio de cabos submarinos, o que reduziu para aproximadamente três horas um processo que poderia levar mais de uma semana (MCFARLANE, 1972). O sistema de transmissão Bartlane é ilustrado na Figura 3.

Os avanços em imagens digitais se aprofundaram na década de 1960, com a evolução do programa espacial e o início da aplicação de captura de imagens na medicina, como por exemplo, em exames de tomografia. Ao longo dos anos, as câmeras fotográficas se tornaram melhores e mais baratas, o que colaborou com a propagação da fotografia analógica e, mais recentemente, da fotografia digital, para usuários comuns.

1.1.2 Aquisição de imagens

Imagens são capturadas por meio do uso de sensores fotográficos. Estes sensores são capazes de capturar frequências das bandas infravermelha, visível ao olho humano e

¹ Disponível em: <<https://www.linkedin.com/pulse/keras-image-preprocessing-scaling-pixels-training-adwin-jahn>>. Acesso em: 27 jul. 2017.




Figura 3 – Sistema de transmissão Bartlane: à esquerda, o componente emissor; à direita, o componente receptor (MCFARLANE, 1972)

ultravioleta do espectro eletromagnético. O espectro eletromagnético é representado na Figura 4.




Figura 4 – Espectro eletromagnético. O espectro contempla desde as ondas de Raios Gama, de comprimento de onda menor, até as ondas de rádio, de comprimento de onda maior, passando pelos espectros de Raios-X, ultravioleta, visível, infravermelho e microondas.²

Um sensor comumente utilizado se trata do dispositivo de carga acoplada, chamado apenas de CCD (do inglês, *Charge-coupled device*). A imagem é obtida através da captura do sinal luminoso que é incidente no objeto e, em seguida refletido, por meio de células fotossensíveis presentes no CCD, que armazenam a carga elétrica proveniente do sinal luminoso. Esta carga elétrica é convertida em imagem através da conversão em um Sinal Composto de Vídeo por determinados circuitos (FILHO; NETO, 1999).

Outro tipo de sensor é o Semicondutor de metal-óxido complementar, ou CMOS (do inglês, *Complementary Metal-Oxide Semiconductor*). Menores e mais baratos que os sensores CCD, tais sensores são organizados na forma de uma matriz de pixels, onde para cada pixel, existe um fotodetector que converte a luz incidente em fotocorrente que é

² Disponível em: <<http://imagine.gsfc.nasa.gov/science/toolbox/emspectrum1.html>>. Acesso em: 28 mai. 2016

convertida para corrente elétrica e, em seguida, para uma imagem (GAMAL; ELTOUKHY, 2005).

Tanto sensores CCD quanto sensores CMOS conseguem capturar as bandas ultravioleta, visível e infravermelha do espectro eletromagnético, mesmo que por vezes as câmeras digitais estejam equipadas com proteções para filtrar as bandas ultravioleta e infravermelha (SPRING; DAVIDSON, 2012). Na Figura 5, é feita uma comparação entre uma imagem capturada usando os dois tipos de sensores no espectro visível.



Figura 5 – Comparação de imagem de sensor CMOS e CCD: à esquerda, uma imagem de sensor DPS-SOC (CMOS); à direita, uma imagem de sensor CCD (GAMAL; ELTOUKHY, 2005)

Existem três principais tipos de captura de sinal eletromagnético: captura espectral, multiespectral e hiperespectral. A captura espectral é feita em uma determinada banda do espectro eletromagnético; a captura multiespectral se refere à captura de 3 a 10 bandas diferentes; por fim, a captura hiperespectral é feita em milhares de bandas diferentes, de comprimentos menores.

1.1.3 Processamento digital de imagens

Segundo o digrama representado na Figura 1, em um sistema de Visão Computacional, Processamento Digital de Imagens compreende as fases de pré-processamento, segmentação e extração de características de uma imagem.

As atividades de processamento digital de imagens são relativas aos processos aplicados a fim de obter algum tipo de resultado, como por exemplo a melhoria da qualidade das imagens através de processos de redução de ruído, extração de informações de objetos presentes na imagem (segmentação, classificação, dentre outras) e operações referentes a funções cognitivas, objeto de estudo da visão computacional (GONZALEZ; WOODS, 2010).

Algumas possíveis aplicações de processamento de imagens tratam do aperfeiçoamento da imagem, em termos de qualidade e nitidez, através de operações de redução ou remoção de ruído (BUADES; COLL; MOREL, 2005), redução no tamanho do arquivo,

utilizando, por exemplo, métodos de compressão de imagens (WALLACE, 1992), técnicas de segmentação de imagens, classificação de objetos, dentre outras.

As primeiras aplicações de processamento de imagens como conhecemos surgiram na década de 1960, coincidindo com o desenvolvimento e aperfeiçoamento do computador digital e o surgimento de linguagens de programação de alto nível. Na época, foram desenvolvidas técnicas de melhoramento de imagens que foram aplicadas em imagens lunares obtidas a partir de sondas espaciais (BILLINGSLEY, 1970), além de outros tipos de aplicações, como demonstrado por Rosenfeld (1969). Na década de 70, surgiram aplicações na medicina, com o advento dos exames de tomografia computadorizada (HOUNSFIELD, 1977). Uma imagem desse exame é exemplificada na Figura 6.




Figura 6 – Primeira imagem obtida através de tomografia computadorizada³

Acompanhando o avanço da fotografia digital, as aplicações de processamento de imagens se disseminaram para outras áreas, como geografia, arqueologia, física, biologia, dentre outras, além do dia a dia do usuário comum.

1.1.3.1 Vizinhança e Conectividade

A vizinhança de um pixel pode ser definida de três formas: 4-vizinhança, vizinhança diagonal e 8-vizinhança. A 4-vizinhança é definida pelos vizinhos horizontais (esquerdo e direito) e verticais (superior e inferior). A vizinhança diagonal é composta pelos quatro pixels à diagonal do ponto analisado. A 8-vizinhança é definida pelos pixels da 4-vizinhança e pelos pixels da vizinhança diagonal (FILHO; NETO, 1999). Estas vizinhanças são ilustradas na Figura 7.

A conectividade entre pixels é definida pela vizinhança e pela cor. Dois pixels podem ser considerados 4-conectados se um dos pixels estiver na vizinhança do outro e se o tom de cor for igual ou semelhante (variando de acordo com o critério definido e o espectro de cores que está sendo trabalhado). Seguindo a mesma lógica, dois pixels são

³ Disponível em: <<http://www.impactscan.org/CThistory.htm>>. Acesso em: 28 mai. 2016




Figura 7 – Os três tipos de vizinhança de pixel. (a) 4-vizinhança; (b) vizinhança diagonal; (c) 8-vizinhança. (FILHO; NETO, 1999)

8-conectados se um deles estiver na vizinhança de 8 do outro pixel e se possuir o mesmo tom de cor.

1.1.3.2 Segmentação de Imagens

O processo de segmentação de imagens consiste na divisão de uma imagem em regiões, cujos pontos compartilham determinadas características entre si. O propósito destas atividades é obter algum tipo de sentido às partes de uma imagem, de forma que seja possível trabalhar computacionalmente com estas informações (SHAPIRO; STOCKMAN, 2000).

As técnicas de segmentação de imagens podem ser divididas em dois grupos: contextuais ou não-contextuais. Enquanto as técnicas contextuais operam de acordo com a região em volta de pontos de interesse, os métodos não-contextuais utilizam como base um parâmetro global, que é aplicado igualmente para cada ponto da imagem (EFFORD, 2000). Além disso, o método pode ser baseado em discontinuidade ou em similaridade: os métodos baseados em discontinuidade se baseiam em mudanças bruscas na imagem, como pontos e linhas isolados; os métodos baseados em similaridade agrupam os pontos de acordo com a similaridade da região (GONZALEZ; WOODS, 2010).

Nos próximos tópicos, são discutidos alguns métodos de segmentação de imagens.

1.1.3.2.1 Limiarização

O processo de limiarização é usado na binarização de imagens onde há uma separação entre os tons de cor do plano de fundo e dos objetos de estudo. Neste caso, a partir de um valor limiar predefinido, os pixels de valores maiores que o limiar recebem valor positivo e os pixels de valores menores que o limiar recebem valor negativo. É possível também definir mais de um limiar, onde as três ou mais regiões recebem os valores que forem definidos (GONZALEZ; WOODS, 2010). Na Figura 8 é apresentada a definição de limiares em histogramas, que representam a distribuição de pixels de uma imagem com relação ao tom de cor (FILHO; NETO, 1999).




Figura 8 – Definição de limiares em histogramas. O eixo y representa a frequência de ocorrência da cor na imagem. O eixo x representa a intensidade de cor. (a) definição de limiar único em histograma; (b) definição de limiar duplo em histograma; (c) histograma que apresenta dificuldade no processo de definição do limiar.⁴

Como pode ser observado na Figura 8c, uma das dificuldades nesse tipo de binarização é encontrar o limiar ideal para que se obtenha um resultado satisfatório. Este processo geralmente envolve análise de histogramas, o que pode necessitar de intervenção manual.

Uma ferramenta que visa automatizar a definição de um limiar é o método de Otsu (OTSU, 1979). Este método visa encontrar o limiar ótimo para o histograma da imagem, iterando por todos os valores possíveis até encontrar o valor que minimiza a variância intraclasse.

Outros métodos trabalham com o agrupamento por critérios de similaridade, como exemplo é possível citar o Kmeans. São definidos dois grupos, cujos centroides iniciais podem ser os extremos do espectro adotado ou pontos aleatórios da imagem. Após a definição dos grupos, cada pixel é atribuído a um deles. O processo é repetido até que se obtenha a convergência, ou seja, até que não haja troca de grupos entre uma iteração e outra (SHAPIRO; STOCKMAN, 2000). O processo pode ser executado, também, com mais de dois grupos.

1.1.3.2.2 Detecção de pontos e linhas

Os processos de detecção de pontos, linhas e bordas são baseados em discontinuidade. Inúmeras técnicas buscam identificar tais discontinuidades, as mais comuns aplicam um processo de convolução (FILHO; NETO, 1999) entre a imagem objeto e uma matriz, denominada máscara convolutiva, de tamanho definido e com pesos diferentes para cada elemento.

De acordo com o (GONZALEZ; WOODS, 2010), o processo de convolução consiste em aplicar uma operação para cada ponto P da imagem processada, de forma que o novo valor do ponto será obtido através da Equação 1.1, onde w corresponde ao valor do ponto

⁴ Disponível em: <<http://www.cse.dmu.ac.uk/~sexton/WWWPages/HIPR/html/threshld.html>>. Acesso em: 25 jul. 2017.

da máscara, z ao valor do ponto na imagem e x se refere à quantidade de pontos da máscara. Na Figura 9 é representada uma máscara utilizada para detectar pontos isolados.

$$R = w_1z_1 + w_2z_2 + \dots + w_xz_x \quad (1.1)$$

-1	-1	-1
-1	8	-1
-1	-1	-1

Figura 9 – Máscara para detecção de pontos (GONZALEZ; WOODS, 2010)

A partir do valor de R , caso este seja maior que um determinado limiar, considera-se que foi encontrado um ponto de interesse (nesse caso, um ponto isolado). O mesmo comportamento se aplica para detecção de retas, porém, em vez de apenas uma máscara, são usadas quatro máscaras diferentes para as possíveis direções da reta (Figura 10). Nesse caso, prevalece o maior valor de R para identificar a direção da reta, caso este valor seja maior que o limiar.

-1	-1	-1	-1	2	-1	-1	-1	-1	2	-1	-1
2	2	2	-1	2	-1	-1	2	2	-1	2	-1
-1	-1	-1	-1	2	-1	2	-1	-1	-1	-1	2
(a) Horizontal			(b) Vertical			(c) +45°			(d) -45°		

Figura 10 – Diferentes máscaras para detecção de linhas (GONZALEZ; WOODS, 2010)

1.1.3.2.3 Detecção de bordas

A detecção de bordas trata da identificação de limites entre regiões que possuem uma certa variação entre os níveis de cinza. Esse procedimento é realizado por meio de filtros espaciais lineares, baseados nos gradientes de luminosidade e laplaciano (FILHO; NETO, 1999).

O processo é feito por meio de máscaras de convolução de tamanho 3x3, chamadas de operadores, que podem ser verticais ou horizontais. Alguns exemplos de operadores são Sobel, Roberts e Prewitt. O resultado da convolução por meio dos operadores de Sobel e Prewitt é ilustrado na Figura 11. Na Figura 12 são representados os operadores utilizados.




Figura 11 – Exemplo do realce de bordas. (a) imagem original; (b) realce de bordas com o operador Prewitt; (c) realce de bordas com o operador Sobel (FILHO; NETO, 1999)

-1	0	+1	+1	+2	+1	+1	0	-1	+1	+1	+1
-2	0	+2	0	0	0	+1	0	-1	0	0	0
-1	0	+1	-1	-2	-1	+1	0	-1	-1	-1	-1
(a)	(b)	(c)	(d)								

Figura 12 – Operadores de realce de bordas. (a) operador vertical de Sobel; (b) operador horizontal de Sobel; (c) operador vertical de Prewitt; (d) operador horizontal de Prewitt.

1.1.3.2.4 Crescimento de região

O processo de crescimento de região tem como objetivo agrupar todos os pixels conexos a um pixel P , considerado como semente do processo. Uma região então será formada em torno desta semente agrupando os pontos que satisfaçam um critério de conectividade e uma regra de similaridade pré-estabelecida com essa semente (SHAPIRO; STOCKMAN, 2000). Isso, por exemplo, pode ser feito por meio do cálculo da média do tom de cinza de cada região e da dispersão do ponto para a região. Caso o grau de similaridade seja satisfatório, o ponto é incorporado à região analisada.

1.1.3.3 Morfologia matemática

A morfologia matemática é um conjunto de técnicas de processamento de imagens que visa extrair informações de formas e texturas de uma imagem (GONZALEZ; WOODS, 2010). Isso é feito por meio de um elemento estruturante, que é usado para percorrer a imagem e verificar se este elemento se encaixa nela.

As diferentes operações de morfologia matemática usam critérios distintos para indicar se um elemento estruturante se encaixa em determinado local da imagem. A partir

disso, o local é transformado de acordo com a operação e com o elemento estruturante utilizado (SHAPIRO; STOCKMAN, 2000).

1.1.3.3.1 Elemento estruturante

Um elemento estruturante é uma imagem binária menor em um determinado formato e tamanho, como, por exemplo: linha, cujo tamanho é definido pelo comprimento; retângulo, cujo tamanho é definido pela medida das duas dimensões; e disco, cujo tamanho é definido pelo diâmetro. A Figura 13 contém exemplos de elementos estruturantes.




Figura 13 – Diferentes elementos estruturantes. (a) formato de quadrilátero de tamanho 3x3; (b) formato de linha de comprimento 5; (c) formato cruz de tamanho 5x5; (d) formato de diamante de tamanho 5x5; (e) fomato de disco de raio 7.

Normalmente, a origem de um elemento estuturante é definida como sendo o centro do elemento. Porém, este pode ser definido em qualquer ponto desejado (SHAPIRO; STOCKMAN, 2000).

1.1.3.3.2 Erosão

O processo de erosão visa reduzir regiões positivas de uma determinada imagem binária. O critério de encaixe da operação de erosão é definido da seguinte forma: posicionando o centro de um elemento estruturante em cada um dos pontos do primeiro plano da imagem, caso algum dos pontos do elemento estruturante estejam em uma região do

plano de fundo, o ponto onde o centro está situado é transformado em plano de fundo (SHAPIRO; STOCKMAN, 2000). O processo de erosão é ilustrado na Figura 14.




Figura 14 – Exemplo do processo de erosão executado com um elemento estruturante no formato de um quadrado de tamanho 3^5

1.1.3.3.3 Dilatação

O processo de dilatação, por sua vez, tem como objetivo alargar regiões positivas de uma imagem. Nesse caso, é considerado que o elemento estruturante encaixa em uma determinada região quando o centro está posicionado em algum dos pontos positivos da imagem. Nessas situações, todos os pixels onde o elemento estruturante estiver presente serão convertidos para o primeiro plano, ou seja, passarão a ser positivos (SHAPIRO; STOCKMAN, 2000). O processo de dilatação é ilustrado na Figura 15.





Figura 15 – Exemplo do processo de dilatação executado com um elemento estruturante no formato de um quadrado de tamanho 3^6

1.1.3.3.4 Fechamento

O processo de fechamento é executado para realizar preenchimento de falhas, como pequenos buracos e fendas, entre pontos positivos de uma imagem binária, além de suavizar os contornos das regiões. Este processo é composto por uma operação de dilatação, seguido de uma operação de erosão (SHAPIRO; STOCKMAN, 2000). O processo de fechamento é ilustrado na Figura 16.


⁵ Disponível em: <<https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm>>. Acesso em: 25 jul. 2017

⁶ Disponível em: <<https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm>>. Acesso em: 25 jul. 2017

Figura 16 – Exemplo do processo de fechamento⁷

1.1.3.3.5 Esqueletização

O processo de esqueletização se refere a transformar um objeto em um esqueleto, que se trata de uma cadeia de caracteres de apenas um pixel de espessura. Um esqueleto é definido por meio do desenho de círculos na borda de uma região. Quando dois círculos se encontram em um e apenas um ponto, este ponto passa a fazer parte do esqueleto da imagem (HARALOCK; SHAPIRO, 1992).

Figura 17 – Exemplo do processo de esqueletização⁸

1.1.3.3.6 Poda

O processo de poda se refere a remover excessos em uma imagem esqueletizada, que não são relevantes para a composição da linha. Isso é feito a partir da remoção iterativa de todos os pixels que possuem apenas um ou nenhum ponto na vizinhança de 8 pixels. Este processo é demonstrado na Figura 18.

⁷ Disponível em: <<https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm>>. Acesso em: 25 jul. 2017

⁸ Disponível em: <<https://homepages.inf.ed.ac.uk/rbf/HIPR2/skeleton.htm>>. Acesso em: 25 jul. 2017




Figura 18 – Exemplo da operação de poda

1.1.3.3.7 Transformada de Hough

A Transformada de Hough é um algoritmo utilizado para encontrar formas geométricas, como linhas e círculos em imagens binárias, mesmo em situações de ruído ou de retas incompletas.

Para detecção de linhas, é adotada a fórmula $\rho = x \cos \theta + y \sin \theta$, de forma que os parâmetros ρ e θ são obtidos a partir de uma linha imaginária que é desenhada da origem até a reta que é descrita, de forma perpendicular. Os parâmetros ρ e θ representam, respectivamente, o tamanho da reta imaginária e o ângulo que esta reta forma com o eixo x . Esta reta é demonstrada na Figura 19.




Figura 19 – Demonstração dos parâmetros que descrevem uma reta (SHAPIRO; STOCKMAN, 2000)

A Transformada de Hough utiliza uma matriz de contagem de duas dimensões, onde a primeira corresponde ao valor de ρ e a segunda ao valor de θ . A partir disso, para cada ponto não-nulo da imagem, é feita uma análise do ponto e da vizinhança e a célula correspondente aos valores encontrados é incrementada, num esquema de votação. Desta forma, os pontos com maior número de votos (ou seja, maior número de ocorrências na matriz de contagem) têm maior probabilidade de corresponder a uma reta verdadeira (SHAPIRO; STOCKMAN, 2000).

1.2 Agricultura de precisão

A agricultura de precisão se trata da aplicação de técnicas de tecnologia da informação no cultivo, a fim de maximizar a produção de uma cultura e minimizar o uso dos recursos empregados, como, por exemplo: água, energia e defensivos agrícolas. A racionalização destes recursos traz diversos benefícios, já que com a redução do desperdício dos recursos e uso eficiente da terra, é possível obter um plantio mais sustentável (SHIRISH; BHALERAO, 2013).

Através do uso do sistema de posicionamento global e de sistemas de informação geográfica, aliados a sistemas de visão computacional, por exemplo, é possível mensurar aspectos de nutrição e desenvolvimento da planta, permitindo que seja feita uma análise mais precisa em termos de produtividade e necessidades.

Alguns dos primeiros trabalhos da área de agricultura de precisão datam da década de 1920. Em Linsley, Bauer et al. (1929), por exemplo, é descrito um método de mensuração de acidez do solo. Por meio de coleta de 23 amostras de superfície, 5 de subsuperfície e 5 de subsolo em determinados pontos de uma área de 40 acres (pouco mais de 16 hectares), é realizado um teste com tiocianato de potássio. Em seguida, os resultados são aplicados a um mapa para que seja definida com precisão a quantidade de calcário que deve ser aplicada em cada área da propriedade para que seja feita a correção da acidez. Entretanto, diferentemente das técnicas atuais, este método não adotava estratégias computacionais.

Alguns anos depois, na década de 1970, já fazendo uso de ferramentas computacionais, Cameron et al. (1971) fizeram estudos em três tipos de solo canadenses para aferir a acurácia de medidas de determinados nutrientes. As três áreas analisadas foram divididas em medidas iguais e foram extraídas diversas amostras do subsolo em profundidades diferentes. Em seguida, as amostras foram submetidas a diferentes soluções químicas para testar a presença de determinados nutrientes e a medida de pH. Foi utilizado um computador para fazer as análises matemáticas e estatísticas, além de aferir a acurácia do método aplicando-se técnicas estatísticas e de simulação para tal.

Já na década de 1980, Kachanoski, Wesenbeeck e Gregorich (1988) fizeram estimativas de irrigação de culturas. Em uma área de 1,5 hectare, foram feitas medidas em 52 pontos com distância de 10 metros entre eles, em diferentes profundidades. Foram extraídas também amostras do solo para medição de nutrientes que poderiam afetar os resultados do método, já que este utiliza da condutividade eletromagnética para inferir sobre a quantidade de água presente.

Mais recentemente, Stafford e Miller (1993) propuseram uma das primeiras aplicações da agricultura de precisão como conhecemos, já que utiliza de sistemas para estimar

⁸ Disponível em: <http://earthobservatory.nasa.gov/Features/PrecisionFarming/precision_farming2.php>. Acesso em: 28 mai. 2016.

a quantidade de herbicida a ser aplicado em uma cultura de forma não-uniforme (ou seja, considerando a variabilidade do espaço). Utiliza de técnicas como detecção de ervas daninhas, localização espacial, mapeamento de campo e controle de máquina.

Atualmente, o emprego de sensoriamento remoto e visão computacional na agricultura é feito em tarefas como mapeamento e monitoramento das propriedades do solo, classificação de espécies de plantas, gerenciamento de pestes, detecção de estresse hídrico, análise de conteúdo químico da folha e controle e monitoramento de ervas daninhas, além de algumas aplicações mais específicas, como identificação de variação de campo, estimativa de produção, estimativa de umidade do solo, dentre outras.

1.2.1 Veículos Aéreos Não-Tripulados

A aplicação de sensoriamento remoto por meio de imagens provenientes de satélites na agricultura possui alguns problemas, relacionados principalmente à dificuldade de obter imagens em um curto espaço de tempo e a integração com sistemas agronômicos, além da incerteza quanto ao retorno financeiro proveniente destas aplicações. Estes problemas podem ser corrigidos com o uso de VANTs pequenos, já que a utilização destes dispositivos se dá de forma bem mais prática que dispositivos de sensoriamento remoto (SWAIN; JAYASURIYA; SALOKHE, 2007).

Existem vários tipos de VANTs disponíveis no mercado, assim como também vários tipos de sensores que podem ser aplicados a estes dispositivos, variando de sensores espectrais de banda visível até sensores hiperespectrais, passando por multiespectrais e sensores de banda próxima ao infravermelho. São empregados também sensores de localização para configuração de rota e unidades de armazenamento para salvar os dados obtidos (ZHANG; KOVACS, 2012).

A aplicação de VANTs permite, por exemplo, que seja feito o mapeamento de ervas daninhas em pastagem, documentação de estresse hídrico, monitoramento de resultados de tratamentos de nitrogênio, dentre outros. Destaca-se também a escassez de estudos relativos ao crescimento da planta com imagens obtidas por meio de tais dispositivos. Vale ressaltar também problemas identificados quanto à confiabilidade e capacidade de tais dispositivos, já que apresentam curto tempo de voo, perda de estabilidade e manobrabilidade em situações adversas, como turbulências e ventos fortes, dentre outros (HARDIN; HARDIN, 2010).

Outro problema do uso de VANTs se refere à baixa altitude de captura, o que implica em uma quantidade maior de capturas do que seria necessário com outras ferramentas de sensoriamento remoto para cobrir uma determinada área, além de adotar métodos de sobreamostragem para evitar imagens borradas, o que aumenta a necessidade de espaço de armazenamento. Gera-se também um problema na geração de mosaicos, já que a correção

manual de distorções geométricas se torna infactível e o tempo de processamento aumenta consideravelmente ([HARDIN; HARDIN, 2010](#)).

Com relação à adoção de VANTs por agricultores, apesar de estarem se popularizando, estes dispositivos ainda despertam receio com relação ao retorno financeiro do investimento, que em alguns países é impactado pela burocracia quanto a procedimentos de regulação de voo ([STAFFORD, 2000](#)).

2 Trabalhos correlatos

Neste capítulo, são descritos alguns trabalhos que propõem métodos de detecção de linhas de plantio. São apresentadas as técnicas adotadas, bem como os resultados que os autores obtiveram com a aplicação destas técnicas.

2.1 Ramesh et. al., 2016

O trabalho desenvolvido por [Ramesh et al. \(2016\)](#) define um método para detecção e contagem de linhas de plantio em lavouras de tomate, a partir de imagens capturadas por um VANT.

Os autores destacam a importância do trabalho de detecção de linhas de plantio, já que a partir disso é possível determinar densidade, vigor e cobertura de uma colheita. As imagens utilizadas no trabalho foram obtidas a partir de um VANT capaz de capturar vídeo em alta resolução. A partir do vídeo, nas situações onde a linha de plantio estava nítida, as imagens foram extraídas e redimensionadas para o tamanho de 676 X 530 pixels. Vale ressaltar que o algoritmo trabalha com imagens RGB.

A binarização das imagens é feita a partir do algoritmo de agrupamento Kmeans, onde os pixels são divididos em dois grupos que correspondem ao primeiro plano e ao plano de fundo da imagem. O algoritmo é executado até que se obtenha a convergência. Os autores salientam que, pelo fato de imagens RGB apresentarem baixa resolução espectral, ocorre uma alta taxa de classificação incorreta dos pixels. Para tratar este problema, são aplicadas operações de morfologia matemática e segmentação.

A princípio, é executada a operação de erosão com o elemento estruturante no formato de disco, com o objetivo de remover ruídos e imperfeições no primeiro plano. Em seguida, aplica-se a operação de fechamento com um elemento estruturante de linha, com o objetivo de remover pixels divergentes no centro das regiões da imagem. A fim de obter a representação exata da forma, é aplicada uma operação de esqueletização. Posteriormente, a imagem passa por um processo de crescimento de região, que tem o objetivo de conectar objetos da imagem que deveriam ser contínuos. São usadas também duas propriedades geométricas chamadas de Índice de Forma e Índice de Densidade. Este processo faz com que possíveis conexões entre objetos distintos sejam removidas, além do ruídos e diferenças de textura remanescentes.

As linhas são extraídas por meio da Transformada Linear de Hough, após a aplicação do algoritmo de detecção de bordas de Canny. Por fim, o processo de contagem das linhas é feito de forma que a quantidade de linhas é incrementada quando há pelo menos 50

pixels pretos entre uma linha e outra.

Em imagens de baixa altitude, o método foi capaz de produzir uma taxa de acerto superior a 90%, enquanto que em imagens de média altitude a taxa de acerto foi inferior a 65%. A taxa de acerto foi calculada de acordo com a classificação das linhas oriundas do processamento, que foram classificadas em verdadeiros positivos ou falsos negativos, representando, respectivamente, as linhas existentes que foram detectadas e que não foram detectadas.

Entretanto, por utilizar a Transformada de Hough tradicional, o algoritmo é ineficaz ao trabalhar com curvas em linhas de plantio, já que este método não contempla a descrição de curvas. As linhas de plantio geralmente apresentam um comportamento retilíneo quando as imagens são capturadas de uma atitude muito baixa, o que aumenta o tempo de captura e os esforços necessários no processo de criação do mosaico e pré-processamento. Além disso, os processos de morfologia matemática e segmentação foram diferentes para cada imagem, de acordo com o melhor resultado apresentado. Num cenário real, espera-se que não seja necessária uma análise manual de cada imagem para avaliação entre as fases do processo, já que seria inviável por se tratar de uma tarefa demorada.

2.2 Pérez-Ortiz et. al., 2015

O trabalho de [Pérez-Ortiz et al. \(2015\)](#) trata da detecção de ervas daninhas em imagens aéreas obtidas por meio de VANTs em plantações de girassol.

Segundo os autores, a presença de ervas daninhas numa lavoura reduz o seu rendimento em cerca de 35%. Outro ponto é que o impacto financeiro pelo uso de herbicidas em toda a lavoura é bastante representativo, além do fato de que esta prática vai contra certas regulamentações ambientais que têm como objetivo a redução no uso de agrotóxicos, visando o bem estar da população e do meio ambiente. Pensando nisso, foi desenvolvido um método de mapeamento da presença de ervas daninhas, o que reduz a aplicação de herbicidas a determinadas regiões, reduzindo o custo e o impacto ambiental da tarefa. Através do uso de VANTs, é viável que seja feito o acompanhamento dos campos periodicamente, possibilitando o monitoramento do crescimento de ervas daninhas e a proposição de soluções mais eficientes para corrigir o problema.

Os autores ressaltam que, enquanto a pesquisa em técnicas de aprendizado de máquina e segmentação de imagens em agricultura de precisão está se popularizando, a identificação de ervas daninhas ainda é um desafio. Isso se deve por, entre outros motivos, diferenciar ervas daninhas da colheita em estágios iniciais de plantio ser uma tarefa complicada. Outros desafios se referem a produzir um mapa de ervas daninhas preciso e oportuno para apoiar a tomada de decisão do produtor, mas este processo pode ser complicado quando não são fornecidas informações contextuais ou quando há diferenças

de iluminação.

As imagens foram capturadas em diferentes altitudes – 30, 60 e 100 metros – para testar a eficiência do método em configurações distintas. O desempenho em altitudes maiores pode ser determinante para o desempenho da aplicação, já que as capturas envolvem processos de produção do mosaico e ajuste das imagens, o que pode ser bastante oneroso. As imagens foram capturadas por dois sensores diferentes: um sensor multiespectral e um sensor RGB.

O pré-processamento da imagem é composto pela formação do mosaico das capturas e, em seguida, a divisão da imagem em partes de 1000x1000 pixels. Em seguida, são calculados dois Índices de Vegetação: um para imagens no espectro visível e outro utilizando o canal vermelho do RGB e a região próxima ao infravermelho. As imagens são binarizadas por meio do método de Otsu. São utilizados dois limiares diferentes, de forma a separar os três grupos de elementos da imagem: solo, ervas daninhas e cultura. Após o processo de binarização, é realizada a detecção de linhas de plantio por meio da Transformada de Hough.

Os resultados obtidos até então são aplicados por métodos de classificação com o objetivo de resolver o problema da detecção de ervas daninhas. São utilizados processos não-supervisionados: Kmeans e Kmeans com repetição, onde as imagens de amostra dos 3 grupos (solo, ervas daninhas e cultura) foram fornecidas como informações de entrada para inicialização dos centroides; semisupervisionados: uma aproximação linear baseada no SVM, onde os conjuntos rotulados são agregados com os conjuntos não-rotulados para treinamento; supervisionados: k-vizinhanças mais próximas, SVM linear e SVM nuclear, onde apenas os conjuntos rotulados foram usados no treinamento. Os parâmetros desses métodos foram limitados de forma a reduzir o custo computacional.

Os métodos se mostraram bastante eficientes ao lidar com imagens capturadas nas alturas de 30 e 60 metros, principalmente quando aplicados os métodos de classificação semisupervisionados. Porém, para praticamente todos os experimentos na altitude de 100 metros, os resultados foram classificados como insatisfatórios. Vale ressaltar que os resultados foram significativamente melhores quando usados os dados produzidos pelo sensor multiespectral.

2.3 Guerrero et. al., 2013

O trabalho de [Guerrero et al. \(2013\)](#) parte de uma abordagem diferente dos outros trabalhos analisados: as imagens são capturadas a partir de um robô que se movimenta pelo solo em vez de um veículo aéreo, e são processadas em tempo real. O objetivo do trabalho é desenvolver um sistema capaz de detectar linhas de plantio em campos de milho em estágios iniciais de plantio. As imagens são capturadas por meio de um sensor CCD

cujas características da lente são conhecidas. A câmera é localizada na parte frontal do robô, inclinada para baixo num ângulo conhecido.

Os autores ressaltam a dificuldade em diferenciar as ervas daninhas de plantas reais, já que os tons de vermelho, azul e verde são semelhantes. Outra característica levantada foi a de que as ervas daninhas aparecem em fragmentos sobrepostos a uma linha de plantio ou de forma isolada. Além disso, parte-se do princípio que as linhas de plantio são acumulados de plantas que seguem alinhamentos específicos orientados ao ponto de fuga, que se refere ao ponto onde a linha deixa de ser visível.

O método é dividido em dois módulos principais: segmentação e estimativa de linhas de plantio. Os métodos de segmentação compreendem: combinação de índices de vegetação a partir da normalização dos níveis de vermelho, verde e azul, onde cada índice possui um peso diferente; em seguida, o valor da combinação dos índices é multiplicado pelo valor normalizado do canal verde; logo depois desse processo, a imagem é binarizada por meio do método de Otsu.

O módulo de estimativa de linhas de plantio trabalha com o fato de que a localização das linhas de plantio pode ser prevista, já que os parâmetros intrínsecos (os parâmetros da lente da câmera, como distância focal e distorção) e extrínsecos (ângulo de captura e possíveis movimentos da câmera) são conhecidos. Entretanto, é necessário que seja feita uma correção, já que o terreno onde o robô anda é irregular e distorções não controladas podem acontecer. Caso não haja correspondência entre o estimado e o presente na imagem, é feita uma correção por meio de um método de regressão linear, onde são estimados dois parâmetros: inclinação e intersecção. Por fim, também é aplicada a Transformada de Hough para detectar as linhas reais, adicionando restrições relativas aos parâmetros conhecidos.

O método foi executado em 240 imagens, obtidas em diferentes condições de iluminação e estágios de crescimento de planta. Considerando o fato de que o processamento é feito em tempo real e que o algoritmo adotado onera o tempo de processamento, o método também foi aplicado nas imagens reduzidas em 67% e 84% e os resultados avaliados. Foi adotado também um parâmetro de tolerância, que se refere à quantidade de pixels em volta da linha de plantio onde serão buscados pixels relativos a linhas de plantio e de ervas daninhas. O método atingiu uma taxa de acerto superior a 75% mesmo em imagens reduzidas em 84%. Para imagens sem redução, a taxa foi superior a 85%.

Apesar dos bons resultados, vale ressaltar que o método depende do conhecimento de um número grande de parâmetros para que o desempenho seja eficiente. Em um ambiente pouco controlado, a aplicabilidade do procedimento é comprometida.

3 Metodologia

Inicialmente, foi definido para a execução dos testes um conjunto de três imagens de lavouras obtidas por meio de VANTs a uma altitude aproximada de 100m, unificadas num mosaico de acordo com a posição geográfica onde a imagem foi capturada e as semelhanças visuais entre elas. As imagens foram fornecidas pela empresa Sensix Soluções em Drones, de Uberlândia, Minas Gerais¹.

As imagens foram selecionadas de forma representativa aos problemas reais das lavouras, como interrupção das linhas e falhas no plantio, presença de ervas daninhas, sombras causadas por árvores e nuvens, e diferenças locais de iluminação causadas por problemas no mosaico. Na Figura 20 é possível observar algumas destas falhas presentes no conjunto de testes do algoritmo. A adoção de tais imagens possibilita que seja analisado o comportamento do algoritmo em situações adversas que ocorrem frequentemente ao se tratar desse tipo de problema.



Figura 20 – Exemplos de falhas recorrentes em imagens aéreas de lavouras

O método proposto por Ramesh et al. (2016) considera uma imagem RGB de 676x530px capturada por um VANT a uma altitude baixa. O processo de segmentação proposto pelos autores envolve um grande número de operações morfológicas, já que a binarização é feita a partir da imagem RGB original, o que faz com que a taxa de classificação incorreta dos pixels seja mais alta do que quando aplicada em imagens em tons de cinza. Além disso, as operações morfológicas executadas foram diferentes para cada uma das imagens apresentadas no resultado, o que dificulta a aplicação em um cenário

¹ <<http://sensix.com.br/>>

real, já que o processo envolve uma análise manual de cada imagem para encontrar o melhor resultado.

O processo de segmentação utilizado baseia-se no método utilizado por [Ramesh et al. \(2016\)](#), porém de forma simplificada, com o objetivo de reduzir a complexidade e uniformizar o processo independente da imagem utilizada. Inicialmente, a imagem RGB é convertida em escala de cinza. Este processo faz com que a binarização seja mais precisa, dispensando uma operação morfológica para redução de ruído. Isto é realizado ao desconsiderar as informações de saturação e tonalidade, e mantendo as informações de luminosidade, isto é, a quantidade de luz presente no ponto.

Em seguida, a imagem em escala de cinza passa por um processo de binarização utilizando o algoritmo Kmeans, que divide todos os pixels da imagem em dois grupos, a partir da inicialização dos centroides com os valores extremos de luminosidade: 0 e 255. Após esta operação, os centroides dos grupos são atualizados e os pixels reclassificados para o grupo cujo centroide representa a menor distância para este pixel. O processo é repetido até que se obtenha a convergência (ou seja, até que não haja nenhuma troca de grupos na iteração) ou até que o número máximo de iterações seja alcançado.

Após o processo de binarização, é realizado o processo de fechamento que é composto por uma operação de dilatação seguido por uma operação de erosão, executados com um elemento estruturante no formato de disco de tamanho 4. Esta operação é realizada para evitar a presença de pontos negativos no centro de uma linha que foi detectada já que, no processo de esqueletização, esta situação pode gerar círculos indesejados.

Em seguida, as linhas passam novamente por um processo de erosão com um elemento estruturante no formato de diamante de raio 4. Este processo tem como objetivo reduzir a espessura e aumentar a distância entre as linhas. Por fim, é realizada uma operação de esqueletização, seguido por uma de poda, gerando a imagem final.

A Transformada de Hough foi então calculada para cada ponto. A partir da matriz de contagem gerada pela transformada, foi realizada a identificação dos principais picos da matriz. Os picos são definidos como os pontos com maior concentração de votos e que formam prováveis linhas. Foi utilizado como limiar 70% do valor máximo da matriz para definição dos picos. Com a definição dos valores de ρ e θ dos picos de Hough, foram identificadas as linhas que compõem a imagem.

Entretanto, as imagens são capturadas de uma altitude onde, por diferenças de terreno e por restrições de maquinário (como as curvas feitas por implementos responsáveis pelo plantio e colheita e a rota percorrida por maquinário de irrigação – pivôs), as linhas de plantio normalmente se curvam em padrões irregulares, tanto de imagem para imagem como de uma linha para outra. A Transformada de Hough proporciona bons resultados ao detectar formas geométricas simples, como retas e círculos; no entanto, ao ser aplicada em




Figura 21 – Processo de segmentação

cenários onde o objetivo é encontrar linhas curvadas, os resultados são insatisfatórios.





Figura 22 – Demonstração de uma curva numa linha de plantio. Ao analisar a imagem em porções menores, a linha possui um comportamento mais retilíneo.

A partir da análise das imagens em recortes menores, é possível observar que as linhas seguem um comportamento mais retilíneo em relação à imagem como um todo, conforme é possível observar na Figura 22. A partir desta situação, visando aprimorar o desempenho da Transformada Linear de Hough, a imagem foi dividida em janelas menores de tamanhos iguais, onde a segmentação e a detecção das linhas são feitas individualmente. Neste cenário, foi possível notar uma melhora considerável no desempenho da transformada, já que não mais se tratava de uma linha curva mas sim de uma reta. Outro ganho obtido com esta estratégia é a redução da influência da diferença de luminosidade existente na imagem, uma vez que a segmentação da imagem por janela colabora para redução desse

efeito.



(a) Demarcação das janelas de processamento (b) Descontinuidade na linha de plantio causada pelo processamento janelado

Figura 23 – Resultado do janelamento

Porém, detectou-se que a adoção do janelamento na detecção das linhas cria um problema no resultado final, já que os segmentos de reta detectados para cada linha de plantio se apresentam de forma desconexa (Figura 23), pelo fato de que não é feita uma análise da região próxima para unificar as linhas. Além disso, por vezes a junção por proximidade é dificultada, uma vez que nem sempre o ponto mais próximo do segmento descontínuo faz parte da mesma linha de plantio. Nestes casos, a junção das linhas mais próximas se daria de forma incorreta.

A fim de solucionar este problema, foi desenvolvido um método de sobreposição de janelas. No janelamento sem sobreposição, cada região da imagem é processada apenas uma vez, o que causa a descontinuidade nas linhas (Figura 23b). No caso do processamento por janelas sobrepostas, ocorrem regiões de transição entre uma janela e outra e, nestes casos, a região é processada duas ou mais vezes em janelas diferentes. Assim, são detectados segmentos concorrentes ou sobrepostos, que garantem a continuidade dos segmentos que formarão a linha de plantio (Figura 24b).

A sobreposição de janelas ocasiona um aumento na quantidade de ruído, correspondente a regiões da imagem que não contêm uma linha de plantio. Este ruído se apresenta na forma de segmentos de reta que não possuem correspondência com a linha de plantio, que por vezes ocorre de forma transladada ou então totalmente desalinhada com a linha de plantio.

A fim de amenizar o problema, foram desenvolvidos três métodos de filtragem desses segmentos, aqui definidos como anômalos. Para cada janela de processamento, é calculado o coeficiente angular de todas os segmentos detectados e, a partir disso, se obtém a mediana




Figura 24 – Resultado do janelamento sobreposto




Figura 25 – Demonstração da aplicação do método de remoção de ruído. As bordas azuis representam a janela de filtragem com coeficiente de 2,0 e as bordas brancas a janela de processamento. (a) imagem antes da remoção de ruído. (b) imagem após remoção de ruído.

dos coeficiente angulares, que definirá a tendência da direção de crescimento das linhas de plantio. Foi utilizada a mediana a fim de reduzir a sensibilidade a valores discrepantes. Caso duas ou mais linhas sejam concorrentes (ou seja, se cruzem em algum ponto do plano) ou estejam a uma distância menor que um determinado limiar, é descartada a linha cujo coeficiente angular mais se distânciava da mediana da janela. São removidos também todos os segmentos cujos coeficientes angulares se diferenciam da mediana em mais de 0,09. Por fim, após o processamento de todas as janelas da imagem, é calculada uma janela de filtragem semi-local cujo tamanho é definido por um multiplicador do tamanho da janela.

Assim como é realizado na janela de processamento, na janela de filtragem é calculada a mediana do coeficiente angular das linhas e as linhas que se diferenciam da mediana em mais de 0,27 são removidas, já que diferem em sentido do restante dos segmentos encontrados. O resultado do filtro é demonstrado na Figura 25.


4 Resultados

Neste capítulo é feita uma discussão dos resultados obtidos com este trabalho. Inicialmente, são descritos os conjuntos de parâmetros adotados na execução do método, bem como o conjunto inicial de imagens utilizado. Em seguida, o método de mensuração da taxa de acerto empregado neste trabalho é descrito. Por fim, os resultados obtidos são analisados.

Tabela 1 – Conjunto dos valores utilizados para os parâmetros de teste

Tamanho da Janela de Processamento (em pixels)	Porcentagem de Sobreposição de Janelas	Multiplicador da Janela de Filtragem
50	0	1,5
100	25	2
150	48	2,5
200		

O método considera três parâmetros necessários para a execução: o tamanho da janela de processamento, a porcentagem de sobreposição e o multiplicador para a janela de filtragem. Os conjuntos dos valores adotados nos testes são apresentados na Tabela 1.



(a) Imagem 1

(b) Imagem 2

(c) Imagem 3

Figura 26 – Imagens utilizadas nos testes preliminares do método

Para definição dos parâmetros, foram realizados testes com valores maiores e menores que o conjunto selecionado. Valores menores que 50 pixels para a janela de processamento resultaram em linhas difusas com relação à angulação, já que não era possível detectar linhas coerentes devido à baixa quantidade de pixels. Além disso, houve um aumento considerável na quantidade de linhas ruidosas e no tempo de processamento. Janelas maiores que 200 pixels geravam segmentos muito grandes, cujas extremidades se distanciavam muito da linha de plantio, de forma que estavam muito próximas das linhas

vizinhas. Outro fato é que, pela baixa quantidade de linhas, a visualização de uma curva a partir dos resultados era dificultoso. Para os parâmetros selecionados, foram obtidos bons resultados.

A respeito da porcentagem de sobreposição, não foram adotados valores maiores de 48% pelo fato de que haveria encontro de linhas que não são de janelas vizinhas. O valor de 0% representa nenhuma sobreposição, ou seja, uma janela começa no primeiro pixel ao lado da janela anterior.




Figura 27 – Resultado da demarcação manual das linhas de plantio das imagens utilizadas no conjunto inicial de testes

Por fim, para o multiplicador da janela de filtragem, valores menores que 1,5 produziram resultados bastante semelhantes aos obtidos sem o filtro semi-local, o que não gerou uma melhoria desejada no resultado final. Para multiplicadores maiores que 2,5, identificou-se um comportamento onde várias linhas não-ruídas estavam sendo removidas, principalmente em situações onde a janela de processamento é maior, o que faz com que a janela de filtragem ocupe boa parte da imagem.




Figura 28 – Demarcação do acerto na imagem detectada. As linhas verdes representam os verdadeiros positivos; as linhas vermelhas representam os falsos negativos; as linhas azuis representam os falsos positivos.

Para o conjunto de testes inicial, as imagens indicadas na Figura 26 foram utilizadas. Foram selecionadas estas imagens para os testes preliminares de forma que fosse possível

mensurar o desempenho da técnica adotada em cenários reais, já que há adversidades como presença de ervas daninhas, descontinuidade em linhas de plantio, sombras e diferenças de luminosidade. Desta forma, é possível garantir o desempenho em situações reais.

Tabela 2 – Distribuição dos resultados para o conjunto de testes inicial. O melhor resultado para cada imagem está representado em negrito. O segundo melhor resultado está representado em itálico.

Janela	Parâmetro		Imagem			Média
	Sobreposição	Filtro	1	2	3	
50	0	1,5	64,867	64,228	57,293	62,129
		2	59,140	63,894	57,211	60,082
		2,5	63,008	64,206	57,789	61,668
	25	1,5	71,452	76,846	64,674	70,991
		2	70,202	77,461	64,931	70,865
		2,5	73,395	78,104	65,100	72,200
	48	1,5	76,694	80,586	70,130	75,803
		2	72,138	80,263	69,473	73,958
		2,5	74,398	79,829	69,110	74,446
100	0	1,5	66,415	72,612	54,173	64,400
		2	66,132	72,372	54,901	64,468
		2,5	66,518	72,184	57,481	65,394
	25	1,5	76,787	83,285	67,248	75,773
		2	76,730	83,842	65,669	75,414
		2,5	76,391	84,600	65,669	75,553
	48	1,5	83,065	86,856	70,757	80,226
		2	80,956	86,688	70,736	79,460
		2,5	82,019	86,881	70,977	79,959
150	0	1,5	63,912	72,444	59,737	65,364
		2	64,127	72,597	60,929	65,884
		2,5	62,788	72,581	59,247	64,872
	25	1,5	80,978	85,015	69,201	78,398
		2	80,725	84,724	65,610	77,020
		2,5	80,874	83,823	67,300	77,332
	48	1,5	84,355	88,349	71,474	81,393
		2	85,384	87,730	71,955	81,690
		2,5	84,537	87,962	72,792	81,764
200	0	1,5	67,052	71,774	58,320	65,715
		2	66,189	71,977	56,833	65,000
		2,5	66,965	72,059	56,833	65,286
	25	1,5	78,771	87,043	69,809	78,541
		2	78,796	<i>88,113</i>	69,809	78,906
		2,5	78,405	87,136	69,809	78,450
	48	1,5	86,637	87,602	77,482	83,907
		2	<i>87,883</i>	87,539	76,842	<i>84,088</i>
		2,5	87,928	87,658	<i>76,842</i>	84,143

Para cada imagem, foram demarcadas manualmente as linhas de plantio (Figura

27), que para fins de cálculo de taxa de acerto, serão consideradas como o resultado ideal. O comprimento final das linhas, considerando a ocorrência de curvas, é conhecido.

A partir disso, são extraídas três medidas nos resultados finais: verdadeiros positivos, que se referem ao comprimento das partes das linhas que foram detectadas pelo algoritmo (ou seja, que há a presença de segmentos de reta próximos à linha demarcada); falsos negativos, que dizem respeito aos trechos das linhas demarcadas que não foram detectados; falsos positivos, correspondentes ao comprimento dos segmentos de reta que foram detectados onde não há uma linha de plantio. As demarcações são exemplificadas na Figura 28.

A partir do cálculo dos valores de verdadeiros positivos, falsos negativos e falsos positivos, a taxa de acerto é calculada a partir do Coeficiente de Jaccard. O cálculo é feito de acordo com a Equação 4.1.

$$Jaccard = \frac{VP}{VP + FN + FP} \quad (4.1)$$

O Coeficiente de Jaccard foi utilizado por desconsiderar verdadeiros negativos, já que, neste caso, estes representam todas as possíveis linhas não detectadas. Os resultados são apresentados na Tabela 2. Os valores estão expressos em porcentagem de acerto.




Figura 29 – Comportamento da taxa de acerto a partir do isolamento dos parâmetros

Na Figura 29 são representadas as taxas de acerto do método a partir do isolamento dos valores dos parâmetros, a partir da média dos resultados apresentados na Tabela 2. É possível notar que a variação no tamanho da janela e na porcentagem de sobreposição se

mostraram bastante significativos no resultado final, enquanto que o resultado foi bastante semelhante, independente dos três tamanhos adotados para a janela de filtragem. Em geral, as janela de 50 e 100 pixels produziram resultados insatisfatórios, enquanto que os resultados foram satisfatórios para as janelas de 150 e 200 pixels, principalmente com a sobreposição de 48%.

Para a segunda parte dos testes foram utilizadas outras cinco imagens, que são demonstradas na Figura 30. Nestes testes, foram aplicados os parâmetros que apresentaram o melhor resultado na primeira fase: janela de 200 pixels, sobreposição de 48% e janela de sobreposição com multiplicador de 2,5 vezes. Os resultados são apresentados na Tabela 3.




Figura 30 – Imagens utilizadas na segunda fase de testes

Tabela 3 – Resultados da segunda fase de processamento

Imagem	% Acerto
4	82,658
5	88,869
6	95,486
7	87,225
8	86,371

A partir da análise dos resultados, é possível notar que o comportamento do método se manteve para outras imagens, já que os resultados foram semelhantes aos obtidos na primeira fase de testes.

5 Conclusão

O trabalho propôs um método para detecção de linhas de plantio em imagens aéreas obtidas por meio de VANTs. O método adotou técnicas de segmentação de imagens e morfologia matemática, como: binarização por meio do algoritmo Kmeans, fechamento, erosão, esqueletização, poda e Transformada de Hough.

Inicialmente, a Transformada de Hough foi aplicada na imagem completa, porém, por se tratar de uma imagem de campo aberto cuja morfologia das linhas de plantio é curva, os resultados foram insatisfatórios, uma vez que a Transformada de Hough é capaz de detectar apenas formas geométricas simples, como círculos e linhas. Como alternativa a este problema, foi proposta uma técnica de processamento particionado da imagem, em janelas de tamanhos iguais pois, quando observadas em porções menores, o comportamento da linha se mostrou retilíneo. Entretanto, esse tipo de processamento gerou descontinuidade nas linhas de plantio reais, o que dificultou a junção dos segmentos. De forma a amenizar o problema da descontinuidade foi empregada uma técnica de sobreposição de janelas. Entretanto, a aplicação do método utilizando janelas pequenas e taxas altas de sobreposição fez com que a quantidade de linhas indesejadas - linhas cujo coeficiente angular distam das linhas da região próxima - aumentassem consideravelmente. Neste trabalho tais linhas foram tratadas como ruído criado pela técnica de processamento. A fim de amenizar esta falha, foram implementados alguns métodos de redução deste tipo de ruído: remoção de segmentos próximos ou concorrentes dentro da janela de processamento, remoção de segmentos discrepantes da mediana das linhas da janela e remoção de segmentos discrepantes da mediana de uma região maior que a janela de processamento, cujo tamanho é definido por uma razão desta janela.

A partir disso, inúmeros testes foram realizados com a finalidade de avaliar a influência dos principais parâmetros (tamanho da janela de processamento, tamanho da janela de ruído e taxa de sobreposição da janela de processamento) no desempenho do algoritmo proposto. Os resultados se mostraram satisfatórios, mesmo em imagens com falhas em linhas de plantio, diferenças de luminosidade e presença de ervas daninhas. Na melhor configuração, com janela de 200 pixels, sobreposição de 48% e janela de filtragem 2,5 vezes o tamanho da janela de processamento, foi possível obter, com o conjunto inicial de testes, uma média de acerto de 84,143%. Nessa configuração foi possível obter taxas de acerto de até 95% considerando o conjunto completo de imagens.

Porém, alguns pontos ainda demandam estudos mais aprofundados, já que em regiões onde as linhas de plantio apresentam falhas maiores, onde há variações severas de luminosidade, grande concentração de ervas daninhas ou quando a cultura está em um

estágio inicial do crescimento da planta, o método apresenta resultados menos satisfatórios. Estes problemas serão tratados em trabalhos futuros, onde serão analisadas outras técnicas de redução de ruído, diferenciação de plantas e diferentes técnicas de segmentação das imagens. Será tratado também o problema da junção dos segmentos de reta, de forma a gerar uma representação mais fiel da linha de plantio.

Referências

- BILLINGSLEY, F. C. Applications of digital image processing. *Applied Optics*, Optical Society of America, v. 9, n. 2, p. 289–299, 1970. Citado na página 15.
- BUADES, A.; COLL, B.; MOREL, J.-M. A non-local algorithm for image denoising. In: IEEE. *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. [S.l.], 2005. v. 2, p. 60–65. Citado na página 14.
- CAMERON, D. et al. Accuracy of field sampling for soil tests. *Canadian journal of soil science*, NRC Research Press Ottawa, Canada, v. 51, n. 2, p. 165–175, 1971. Citado na página 24.
- CARVALHO, I. F. Agricultura de precisão: boletim técnico. *Brasília: Mapa/ACS*, 2011. Citado na página 8.
- EFFORD, N. *Digital image processing: a practical introduction using java (with CD-ROM)*. [S.l.]: Addison-Wesley Longman Publishing Co., Inc., 2000. Citado na página 16.
- FILHO, O. M.; NETO, H. V. *Processamento digital de imagens*. [S.l.]: Brasport, 1999. Citado 8 vezes nas páginas 11, 12, 13, 15, 16, 17, 18 e 19.
- GAMAL, A. E.; ELTOUKHY, H. Cmos image sensors. *Circuits and Devices Magazine, IEEE*, IEEE, v. 21, n. 3, p. 6–20, 2005. Citado na página 14.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento digital de imagens*. 3. ed. Rio de Janeiro: Pearson Prentice Hall, 2010. Citado 6 vezes nas páginas 12, 14, 16, 17, 18 e 19.
- GUERRERO, J. M. et al. Automatic expert system based on images for accuracy crop row detection in maize fields. *Expert Systems with Applications*, Elsevier, v. 40, n. 2, p. 656–664, 2013. Citado na página 29.
- HARALOCK, R. M.; SHAPIRO, L. G. *Computer and robot vision*. [S.l.]: Addison-Wesley Longman Publishing Co., Inc., 1992. v. 1. Citado na página 22.
- HARDIN, P. J.; HARDIN, T. J. Small-scale remotely piloted vehicles in environmental research. *Geography Compass*, Wiley Online Library, v. 4, n. 9, p. 1297–1311, 2010. Citado 2 vezes nas páginas 25 e 26.
- HERWITZ, S. et al. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. *Computers and electronics in agriculture*, Elsevier, v. 44, n. 1, p. 49–61, 2004. Citado na página 8.
- HOUNSFIELD, G. N. *Computerized tomography comprising laterally shifting detected beams within a rotated fan of radiation*. [S.l.]: Google Patents, 1977. US Patent 4,041,315. Citado na página 15.
- JI, R.; QI, L. Crop-row detection algorithm based on random hough transformation. *Mathematical and Computer Modelling*, Elsevier, v. 54, n. 3, p. 1016–1020, 2011. Citado 2 vezes nas páginas 8 e 9.

- KACHANOSKI, R.; WESENBEECK, I. V.; GREGORICH, E. Estimating spatial variations of soil water content using noncontacting electromagnetic inductive methods. *Canadian Journal of Soil Science*, NRC Research Press Ottawa, Canada, v. 68, n. 4, p. 715–722, 1988. Citado na página [24](#).
- LINSLEY, C. M.; BAUER, F. C. et al. Test your soil for acidity. *Circular, University of Illinois, Agricultural Experiment Station*; no. 346, Urbana, Ill.: University of Illinois,, 1929. Citado na página [24](#).
- LÓPEZ-GRANADOS, F. Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research*, Wiley Online Library, v. 51, n. 1, p. 1–11, 2011. Citado na página [8](#).
- MCFARLANE, M. D. Digital pictures fifty years ago. *Proceedings of the IEEE*, IEEE, v. 60, n. 7, p. 768–770, 1972. Citado 2 vezes nas páginas [12](#) e [13](#).
- MERON, M. et al. Crop water stress mapping for site-specific irrigation by thermal imagery and artificial reference surfaces. *Precision agriculture*, Springer, v. 11, n. 2, p. 148–162, 2010. Citado na página [8](#).
- OTSU, N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 9, n. 1, p. 62–66, 1979. Citado na página [17](#).
- PAYNE, A. B. et al. Estimation of mango crop yield using image analysis–segmentation method. *Computers and Electronics in Agriculture*, Elsevier, v. 91, p. 57–64, 2013. Citado na página [8](#).
- PÉREZ-ORTIZ, M. et al. A semi-supervised system for weed mapping in sunflower crops using unmanned aerial vehicles and a crop row detection method. *Applied Soft Computing*, Elsevier, v. 37, p. 533–544, 2015. Citado na página [28](#).
- PIERCE, F. J.; NOWAK, P. Aspects of precision agriculture. *Advances in agronomy*, Elsevier, v. 67, p. 1–85, 1999. Citado na página [8](#).
- RAMESH, K. et al. Detection of rows in agricultural crop images acquired by remote sensing from a uav. *International Journal of Image, Graphics and Signal Processing*, Modern Education and Computer Science Press, v. 8, n. 11, p. 25, 2016. Citado 3 vezes nas páginas [27](#), [31](#) e [32](#).
- ROSENFELD, A. Picture processing by computer. *ACM Computing Surveys (CSUR)*, ACM, v. 1, n. 3, p. 147–176, 1969. Citado na página [15](#).
- SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, Elsevier, v. 72, n. 1, p. 1–13, 2010. Citado na página [8](#).
- SHAPIRO, L.; STOCKMAN, G. *Computer Vision*. 2000. Citado 7 vezes nas páginas [11](#), [16](#), [17](#), [19](#), [20](#), [21](#) e [23](#).
- SHIRISH, S. P.; BHALERAO, S. A. Precision farming: The most scientific and modern approach to sustainable agriculture. 2013. Citado na página [24](#).

- SPRING, K. R.; DAVIDSON, M. W. *Quantum Efficiency*. Olympus Microscopy Resource Center, 2012. Disponível em: <<http://www.olympusmicro.com/primer/digitalimaging/concepts/quantumefficiency.html>>. Acesso em: 27 mai. 2016. Citado na página 14.
- STAFFORD, J.; MILLER, P. Spatially selective application of herbicide to cereal crops. *Computers and Electronics in Agriculture*, Elsevier, v. 9, n. 3, p. 217–229, 1993. Citado na página 24.
- STAFFORD, J. V. Implementing precision agriculture in the 21st century. *Journal of Agricultural Engineering Research*, Elsevier, v. 76, n. 3, p. 267–275, 2000. Citado na página 26.
- SWAIN, K. C.; JAYASURIYA, H. P.; SALOKHE, V. M. Suitability of low-altitude remote sensing images for estimating nitrogen treatment variations in rice cropping for precision agriculture adoption. *Journal of Applied Remote Sensing*, International Society for Optics and Photonics, v. 1, n. 1, p. 013547–013547, 2007. Citado na página 25.
- TILLET, R. Image analysis for agricultural processes: a review of potential opportunities. *Journal of agricultural Engineering research*, Elsevier, v. 50, p. 247–258, 1991. Citado na página 8.
- WALLACE, G. K. The jpeg still picture compression standard. *Consumer Electronics, IEEE Transactions on*, IEEE, v. 38, n. 1, p. xviii–xxxiv, 1992. Citado na página 15.
- WEN, C.; ZHU, Q. Dimension reduction analysis in image-based species classification. In: IEEE. *Intelligent Computing and Intelligent Systems (ICIS), 2010 IEEE International Conference on*. [S.l.], 2010. v. 3, p. 731–734. Citado na página 8.
- 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 na página 25.