

IURI REZENDE SOUZA

**IDENTIFICAÇÃO DE LINHAS DE
PLANTIO EM IMAGENS AÉREAS DE
LAVOURAS**



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA

Agosto de 2017

IURI REZENDE SOUZA

**IDENTIFICAÇÃO DE LINHAS DE PLANTIO EM
IMAGENS AÉREAS DE LAVOURAS**

Trabalho de Conclusão de Curso (TCC)
apresentado à Faculdade de Engenharia
Mecânica da Universidade Federal de Uber-
lândia, como requisito à obtenção do título
de Bacharel em Engenharia Mecatrônica.

Orientador: Prof. Dr. Maurício Escarpinati

Uberlândia – MG

Agosto de 2017

Dedicatória

Dedico este trabalho aos meus pais,
que tanto me apoiaram
nestes anos de graduação

“Quando você olha muito perto de um jornal, tudo o que vê é uma bagunça de pequenos pontos de tinta sobre papel. Ao afastar-se, verá que esses pontos desconexos fazem sentido, contam histórias e nos abrem ao mundo. Não são apenas pontos, está tudo conectado”

Aaron Davis, em obra de
C. Jay Cox, tradução livre

Agradecimentos

Gostaria de agradecer a todas as pessoas que diretamente fizeram parte desta jornada de Graduação.

Aos meus pais, Milton Luiz de Souza e Maria Francisca Rodrigues Rezende, por todo apoio incondicional e irrestrito necessário ao cumprimento deste sonho.

Ao Prof. Dr. Mauricio Cunha Escarpinati, pela orientação dada neste trabalho, fundamental para a conclusão do mesmo.

À Sensix, nas pessoas de Antonio Carlos Ribeiro Oliveira Jr. e Thomaz Lemos Olivieri Rodrigues Alves, pelas oportunidades de crescimento profissional e pelo material fornecido.

À Universidade Federal de Uberlândia e à Faculdade de Engenharia Mecânica, pela oportunidade de realizar este curso.

Aos Professores, pelas aulas e orientações que me fizeram crescer academicamente.

À minha irmã Iara Rezende Souza, pela confidencialidade durante estes anos.

Ao meu namorado Franco Luis Loo Zevallos, pelo amor e carinho dado neste último ano da graduação.

À Equipe de Desenvolvimento em Robótica Móvel, pela oportunidade de dedicação que se provou crucial para o meu desenvolvimento técnico.

Aos colegas e professores envolvidos na Olimpíada Brasileira de Matemática, em especial ao Prof. Dr. Antonio Carlos Nogueira, pela motivação em estudar temas complexos e superar cada vez mais as próprias conquistas.

Aos envolvidos nas Maratonas de Programação, pelos treinamentos que foram essenciais no desenvolvimento das minhas habilidades.

Aos colegas do curso de Graduação em Engenharia Mecatrônica, pelos bons momentos de estudos compartilhados.

Aos colegas e envolvidos no intercâmbio para a University of Southern California, pela excelente oportunidade de crescimento pessoal.

Aos meus amigos e familiares e a todos que me proporcionaram bons momentos de descontração em meio aos trabalhos da graduação.

Resumo

Encontrar linhas de plantio em imagens aéreas de plantações é um problema importante para diversas necessidades da agricultura, tais como planejamento de cultura e plantio, estimativa de produção e contagem de plantas. Este trabalho cobre o problema de dada uma imagem aérea RGB de uma lavoura, classificar e retornar as localizações das linhas de plantio. Além disso, como resultado do algoritmo proposto, as linhas são retornadas como sequências de pontos, que podem ser utilizadas para outros trabalhos. Uma das dificuldades do trabalho foi encontrar trabalhos relacionados com este problema, já que este trabalho utiliza imagens aéreas como entrada e também devido ao fato de este trabalho tentar tratar falhas de plantio, que são muito comuns em aplicações de agricultura. O problema foi tratado tentando encontrar plantas individuais, depois encontrando as linhas a partir das localizações de plantas e direções gerais, e depois filtrando e unindo as linhas geradas para tratar os ruídos de plantas daninhas e falhas de plantio. Os resultados foram avaliados utilizando os comprimentos das linhas para verdadeiros positivos, falsos positivos e falsos negativos para avaliação com o teste estatístico F-1. ¹

¹ Palavras-chave: *Processamento Digital de Imagens. Veículos Aéreos Não-Tripulados. Linhas de Plantio.*

Abstract

Finding rows on aerial images of row-planting crops is an important problem for many agricultural needs, such as cultivation and crop planning, production estimation and plant counting. This paper covers the problem of given an RGB aerial image of a crop, classify and output the location of the crop rows. Also, as the result of the proposed algorithm, rows are output as sequence of points, which can be used for further results. There are few related works to this problem, mainly because this paper uses aerial images for the field images and because it looks into the problem of planting gaps, which is very common in farming applications. The problem was tackled by finding individual plants, then finding lines from plant locations and nearby general directions, and then filtering and merging the lines to solve the problems of weed species and planting gaps. Results were evaluated by the lines lengths for true positives, false positives and false negatives for evaluation with the F-1 statistical test. ²

² Keywords: *Digital Image Processing. Unmanned Aerial Vehicles. Crop rows.*

Lista de ilustrações

Figura 2.1 – Exemplo de mapa de NDVI gerado por VANT	5
Figura 2.2 – VANT SX2, utilizado na captura das imagens	6
Figura 2.3 – Imagem binarizada que representa um cavalo	7
Figura 2.4 – Transformada de distância da Figura 2.3	8
Figura 2.5 – Visualização da operação de erosão	9
Figura 2.6 – Utilização da erosão para filtrar ruídos	10
Figura 2.7 – Visualização da operação de dilatação	10
Figura 2.8 – Visualização da operação de abertura	11
Figura 2.9 – Visualização da operação de fechamento	12
Figura 2.10 – Resposta do olho humano para os cones de tipo x, y e z em função do comprimento de onda	13
Figura 2.11 – Diagrama de cores CIE 1931 com luminância fixa	13
Figura 2.12 – Espaço de cores RGB representadas em um cubo	14
Figura 2.13 – Matriz de pontos coloridos	15
Figura 2.14 – Sub-espço de cores do padrão RGB	16
Figura 2.15 – Espaço de cores HSV representadas em um cilindro	16
Figura 4.1 – Fluxograma geral do algoritmo utilizado	22
Figura 4.2 – Imagem RGB original sem sobreposição foliar	24
Figura 4.3 – Imagem segmentada sem sobreposição foliar	24
Figura 4.4 – Imagem RGB original com sobreposição foliar	25
Figura 4.5 – Imagem segmentada com sobreposição foliar	25
Figura 4.6 – Fluxograma do algoritmo de área-ponto	27
Figura 4.7 – Transformada de distância de uma região similar à da Figura 4.8	27
Figura 4.8 – Visualização do algoritmo de área-ponto	27
Figura 4.9 – Fluxograma do algoritmo de buscar linhas gerais	29
Figura 4.10 – Ponto mais próximo P de cada ponto base B	29
Figura 4.11 – Exemplo de pontos vizinhos e suas direções	30
Figura 4.12 – Parte da imagem aérea de uma linha de plantio	31

Figura 4.13 – Discretização e enumeração das direções	31
Figura 4.14 – Retângulo mostrando os pontos candidatos à ligação . . .	32
Figura 4.15 – Fluxograma do algoritmo de melhorar as linhas encontradas	34
Figura 4.16 – Um ângulo a ser filtrado	35
Figura 4.17 – Um ponto espúrio no final de uma linha	35
Figura 4.18 – Falhas de plantio	36
Figura 4.19 – Fluxograma da decisão de conectar linhas	37
Figura 4.20 – Paralelogramos utilizados para predizer possíveis pontos de continuação	38
Figura 4.21 – Estimativa dos possíveis pontos de continuação	40
Figura 5.1 – Resultado do processamento de cana-de-açúcar (#01) . .	43

Lista de tabelas

Tabela 4.1 – Exemplo de distribuição de direções para a Figuras 4.11 e 4.13	32
Tabela 5.1 – Percentagens dos resultados utilizando 20 imagens diferentes.	42

Lista de abreviaturas e siglas

AP	Agricultura de Precisão
CIE	<i>Comission Internationale de l'Éclairage</i>
GPS	<i>Global Positioning System</i>
HSV	<i>Hue, Saturation, Value</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
PDI	Processamento Digital de Imagens
RGB	<i>Red, Blue, Green</i>
VANT	Veículo Aéreo Não-Tripulado

Lista de símbolos

A	Ponto ligado a B
$\bar{A}$	Distância média entre pontos adjacentes
atan2	Arco-tangente de dois argumentos
B	Ponto base
$\overrightarrow{BP}$	Vetor que sai do ponto base B e chega ao ponto P
b	Intensidade azul do pixel
C	Ponto ligado a B
D	Distância entre linhas de plantio vizinhas
d	Distância entre plantas adjacentes na mesma linha
$\text{dist}(A, B)$	Distância entre A e B
E	Ponto no final de uma linha
$\exp$	Função exponencial de base natural
g	Intensidade verde do pixel
h	Matiz do pixel
I	Imagem de origem
I'	Imagem de destino
i, j, k	Índices ou identificadores
L	Último ponto da linha
l	Linha existente

N	Número de pontos considerados
N_i	Próximo ponto predito
n	Parâmetro inteiro
P	Ponto mais próximo de B
P_i	Ponto na mesma linha de B
P_i	Ponto direta ou indiretamente conectado a B
π	Constante matemática, medida do ângulo de meia-volta
R	Conjunto de pontos preditos
r	Intensidade vermelha do pixel
ρ	Raio do sistema de coordenadas polar
S	Penúltimo ponto da linha
s	Saturação do pixel
$\Theta(B)$	Direção predominante na região do ponto B
θ_i	Direção de número i
θ	Inclinação do sistema de coordenadas polar
v	Valor do pixel
x	Coordenada horizontal do pixel
Δx	Diferença entre as coordenadas horizontais
y	Coordenada vertical do pixel
Δy	Diferença entre as coordenadas verticais
z	Variável normalizada
$\angle$	Ângulo
$\in$	Pertence
$\neq$	Diferente
$>$	Maior que

Sumário

Capítulo 1	INTRODUÇÃO	1
Capítulo 2	FUNDAMENTAÇÃO TEÓRICA	3
2.1	Agricultura de Precisão	3
2.1.1	NDVI	3
2.1.2	Outras considerações	5
2.2	Veículos Aéreos Não-Tripulados	6
2.3	Processamento Digital de Imagens	7
2.3.1	Binarização de imagens	7
2.3.2	Transformada de distância	8
2.3.3	Operações morfológicas	8
2.3.4	Espaço de cores	12
Capítulo 3	TRABALHOS CORRELATOS	19
Capítulo 4	MATERIAIS E MÉTODOS	21
4.1	Localização de Plantas	21
4.1.1	Segmentação	22
4.1.2	Centroides	23
4.1.3	Área-ponto	26
4.2	Busca de Linhas Gerais	28
4.2.1	Selecionar direção do ponto mais próximo	28
4.2.2	Selecionar direção predominante	28
4.2.3	Conectar pontos vizinhos de linha	30
4.2.4	Descartar ligações em excesso	33
4.3	Melhorar Linhas Encontradas	33
4.3.1	Suavizar ângulos agudos	33
4.3.2	Cortar finais de linhas	34
4.3.3	Descartar linhas pequenas	35
4.3.4	Conectar linhas parecidas com polinômios	35
4.3.5	Suavizar ângulos pequenos	39
Capítulo 5	RESULTADOS E DISCUSSÕES	41
5.1	Resultados	41
5.2	Discussões	42
Capítulo 6	CONCLUSÃO E TRABALHOS FUTUROS	45

6.1	Conclusão	45
6.2	Trabalhos Futuros	46
REFERÊNCIAS		47

CAPÍTULO I

Introdução

A Agricultura de Precisão faz uso de várias tecnologias de imageamento e mapeamento, para aplicações tais como estimativa de crescimento ([KATAOKA, 2003](#)) e identificação de outras importantes características agronômicas ([SANKARAN, 2015](#)). O avanço dos Veículos Aéreos Não Tripulados (VANTs) e dos sistemas de captura de imagens impulsionou mais tecnologias de imageamento para a agricultura de precisão, tais como as imagens estudadas em ([BLACKMER; SCHEPERS, 1996](#)).

Um dos problemas de interesse nessa área é encontrar onde estão as linhas de plantio e onde a plantadeira falhou. Para resolver esse problema, atualmente, utilizam-se pessoas que manualmente verificam onde estão as linhas e onde nessas linhas existem as falhas.

A viabilidade comercial da identificação manual das linhas de plantio é um indicativo das dificuldades da automatização dessa tarefa. As plantas em questão podem ser confundidas com plantas daninhas, a resolução da imagem pode ser baixa demais, há ruídos e obstáculos, como postes, cercas e árvores, há sombras, tanto de nuvem como de outros objetos, existem falhas de plantio e existem sobreposições entre as folhas das plantas. Tudo isso dificulta que essa identificação seja feita de modo automatizado.

Dentro desse contexto, a proposta deste trabalho é encontrar as linhas de plantio de maneira automática, utilizando-se de algoritmos de processamento de imagens. Assim, pode-se desenvolver a área e obter resultados de qualidade similar com menores custos operacionais.

Como abordagem para solução do problema apresentado, neste trabalho buscou-se detectar cada planta existente na imagem e então utilizar essas localizações para agrupá-las na forma de linhas. Para isso, foi-se desenvolvido um algoritmo para a detecção de linhas, que foi o objetivo do

trabalho. É importante que o algoritmo tenha alguma robustez com relação a obstáculos e falhas de plantio, para que sirva de base para aplicação em trabalhos futuros. Além disso, é uma condição imposta que as linhas de plantio estejam desconexas umas das outras na imagem e que a distância entre plantas seja consideravelmente menor que a distância entre linhas, como é o caso do café, da cana, da laranja e da soja nos estádios iniciais.

A primeira aplicação comercialmente viável das linhas de plantio encontradas é a busca por falhas de plantio. Essas falhas são utilizadas comercialmente para inúmeras aplicações, em especial para o replantio em culturas perenes e semi-perenes (VEIGA, 2003).

Outra possibilidade de aplicação é na utilização como referência em máquinas agrícolas que utilizam o georreferenciamento das linhas de plantio para seu uso semiautomatizado. Tais máquinas utilizam o sinal do GPS e o comparam com o sinal de referência dado pelas linhas encontradas para corrigir sua trajetória.

Este trabalho está dividido da seguinte maneira: o capítulo 2 apresenta a fundamentação teórica, enquanto o capítulo 3 apresenta os trabalhos correlatos. O capítulo 4 discute o algoritmo desenvolvido, o capítulo 5 discorre sobre os resultados e o 6 conclui, apontando para trabalhos futuros.

CAPÍTULO II

Fundamentação Teórica

2.1 Agricultura de Precisão

A agricultura de precisão é um conjunto de técnicas utilizadas na gestão agrícola que permitem o manejo de uma plantação de acordo com características locais do solo (WHELAN; MCBRATNEY, 2000).

Várias das ferramentas utilizadas na agricultura de precisão dividem o talhão em pequenas sub-áreas que representam as características locais da lavoura, chamadas em conjunto de *grid* (MCBRATNEY; PRINGLE, 1999). Em cada elemento do *grid* é feita uma análise de solo, de onde se retiram as propriedades e o agrônomo responsável elabora as receitas de fertilização adequadas para o local. Isso gera mapas de fertilidade do talhão e mapas de aplicação de insumos.

Máquinas agrícolas projetadas especificamente para a agricultura de precisão possuem a capacidade tecnológica de ler os mapas de aplicação, identificar a própria localização por tecnologia de georreferenciamento e variar a aplicação do insumo agrícola de acordo com o recomendado para a localização da máquina (BRISCO, 1998).

Algumas máquinas colheitadeiras possuem tecnologia para, em cada ponto amostrado de localização, medir a produção local, gerando, assim, um mapa de produtividade e permitindo a validação das técnicas utilizadas naquele talhão (ZHANG, 2002).

2.1.1 NDVI

Durante as fases de crescimento das plantas, pode-se observar como as plantas se comportam em relação à radiação eletromagnética refletida pelas folhas. De um modo mais grosseiro, observa-se que plantas muito

debilitadas possuem folhas com cores que diferem das cores das folhas de plantas saudáveis (CHAERLE; STRAETEN, 2001). De um modo mais refinado, é possível medir as intensidades de radiações de diferentes faixas do espectro eletromagnético e obter, a partir de cálculos normalizados utilizando os valores medidos, um índice de vegetação que reflete a saúde da planta. Utilizando-se de comprimentos de onda fora da faixa do visível, como o infravermelho próximo, é possível detectar problemas da planta bem antes do problema se manifestar visivelmente (CHAERLE; STRAETEN, 2001).

Um desses índices é o *índice de vegetação por diferença normalizada*, ou NDVI, que utiliza a faixa do espectro eletromagnético do infravermelho próximo (*Near Infrared*, ou NIR) e a faixa do vermelho. O NDVI é calculado a partir da seguinte fórmula:

$$\text{NDVI} = \frac{\text{NIR} - \text{vermelho}}{\text{NIR} + \text{vermelho}}, \quad (2.1)$$

de modo que os valores de NDVI variam dentro do intervalo $[-1, 1]$. Além disso, da fórmula pode-se observar que reflectâncias mais altas de NIR implicam em valores mais altos de NDVI. Mais especificamente, o valor de NDVI é positivo se, e somente se, o valor medido do NIR é maior que o valor do vermelho (ROUSE, 1974).

A possibilidade de observar a saúde da planta por sensores ópticos de radiação e a possibilidade de encontrar problemas na plantação antes de observáveis a olho nu utilizando o índice NDVI tem impulsionado a utilização comercial do sensoriamento remoto de plantações (ZHANG, 2012). Tais aplicações comerciais incluem tanto satélites quanto os veículos aéreos não-tripulados.

Os satélites, com sensores ópticos NIR e possivelmente sensíveis a outras faixas de frequência para outras aplicações, não são geoestacionários, devido ao pouco e concorrido espaço com essa propriedade, de modo que o ciclo de passagem sobre determinada plantação pode chegar a alguns dias. Além disso, nuvens podem aparecer na linha de visão entre o satélite e a lavoura, o que impede uma análise mais global e confiável dos mapas de NDVI gerado.

Vale destacar que a água da nuvem absorve boa parte da radiação infravermelha recebida, o que implica que o NDVI da água é negativo e muito baixo, conforme a equação 2.1. Isso permite que a nuvem seja detectada e que a análise do mapa gerado por satélite seja somente nas sub-áreas e datas em que não existe cobertura de nuvens.

Já os VANTs sobrevoam a plantação por baixo das nuvens. Isso permite que o mapa de NDVI, como o mostrado na Figura 2.1, seja gerado mesmo em dias nublados. Apesar disso, como a nuvem absorve parte da radiação infravermelha, a sombra gerada pela nuvem sobre a plantação ainda possua um NDVI menor, de modo que os mapas ficam mais informativos em dias em que o efeito das nuvens é homogêneo sobre toda a área mapeada.




Figura 2.1 – Exemplo de mapa de NDVI gerado por VANT

Fonte: Sensix

Diferentemente dos satélites, em que uma fotografia cobre grandes áreas, o sobrevoos dos VANTs possuem como saída várias imagens que cobrem pequenas áreas e que, portanto, devem ser unidas utilizando-se um processo conhecido como ortorretificação ([LALIBERTE, 2008](#)). A ortorretificação toma as imagens capturadas pelo VANT e gera um mapa georreferenciado em que é possível mapear cada pixel a um par de coordenadas geográficas.

2.1.2 Outras considerações

Além do NDVI, uma potencial aplicação dos VANTs na agricultura de precisão é a investigação das linhas de plantio e como consequência o cálculo de falhas de plantio em culturas perenes e semi-perenes. Isso já é feito comercialmente, porém de modo semi-automatizado. Pessoas desenham as linhas manualmente por sobre o mapa, e após isso encontram as falhas por inspeção visual, o que torna o processo lento e oneroso.

2.2 Veículos Aéreos Não-Tripulados

A aviação tem se beneficiado muito da mecatrônica, especialmente no que tange ao controle. Sistemas com sensores de posição e orientação nos 3 eixos geram sinais que podem ser utilizados para comparar com valores desejados e atuar nas superfícies de controle do avião, permitindo a navegação automática da aeronave para pontos previamente escolhidos (VALAVANIS; VACHTSEVANOS, 2014). Isso possibilitou a criação e o desenvolvimento de Veículos Aéreos Não Tripulados (VANTs).



Figura 2.2 – VANT SX2, utilizado na captura das imagens

Fonte: Sensix

O VANT SX2, mostrado na Figura 2.2, possui sensores de GPS, sensor magnético (bússola) nos três eixos espaciais, giroscópio e acelerômetro também nos três eixos e tubo de Pitot, que permitem a uma controladora obter posicionamento completo do VANT, assim como sinais de velocidade e aceleração. Ele ainda possui um sensor óptico, que permite a obtenção de imagens da área sobrevoada.

Além disso, o VANT possui atuadores sobre as superfícies de controle *aileron* nas duas asas, e controle sobre o motor que gira as hélices. Tais elementos, juntamente com uma unidade controladora, permitem que o VANT navegue por um caminho especificado e obtenha imagens em posições especificadas.

Após a obtenção de várias fotos com georreferência, um *software* de ortomosaicagem permite que as imagens sejam unidas em um mapa da área sobrevoada. Estas imagens então estão prontas para análise e podem ser empregadas nas mais variadas aplicações.

2.3 Processamento Digital de Imagens

As imagens são estruturas de dados bidimensionais, onde cada elemento é chamado *pixel*. As posições dos elementos da estrutura matricial refletem as posições espaciais dos pixels. Dessa maneira, as coordenadas espaciais do pixel na imagem são diretamente mapeadas às posições dos elementos (GONZALEZ; WOODS, 2002).

Cada pixel representa uma cor, que é um elemento em um *espaço de cores*. Existem vários espaços de cores que representam cores diferentes de maneiras diferentes. Para uma imagem em escala de cinza, por exemplo, uma possível maneira de representar a cor é por um único número real v . Para espaços de cores coloridos, representa-se a cor em um espaço tridimensional (GONZALEZ; WOODS, 2002).

2.3.1 Binarização de imagens

Uma imagem binarizada ou segmentada é uma imagem onde os pixels são sempre 0 ou 1, ou seja, se v é o valor do pixel, $v \in \{0, 1\}$. Neste trabalho, atribui-se a cor branca a pixels de valor 1 e cor preta a pixels de valor 0. Um exemplo de imagem binarizada pode ser encontrado na Figura 2.3. Note que nessa imagem somente há pixels pretos e brancos.

Em imagens de diferentes tons na escala de cinza, serão utilizados neste trabalho valores reais entre 0 e 1.




Figura 2.3 – Imagem binarizada que representa um cavalo

2.3.2 Transformada de distância

A transformada de distância (BREU, 1995) é uma transformação de uma imagem binária I para uma imagem em escala de cinza I' de mesmas dimensões de I , com as seguintes propriedades:

- Pixels pretos em I são transformados em pixels pretos em I' .
- Pixels brancos em I são transformados em pixels não pretos, isto é, $v \neq 0$, em I' .
- A distância euclidiana, de um pixel branco em I ao pixel preto mais próximo é proporcional ao valor do pixel correspondente em I' .

Um exemplo de transformada de distância é mostrado na Figura 2.4.




Figura 2.4 – Transformada de distância da Figura 2.3

Há transformadas de distância que se utilizam de outras normas que não a euclidiana, como a norma do máximo, mas para a utilização neste trabalho, somente será utilizada a norma euclidiana (LAGERSTROM; BUCKLEY, 2012).

2.3.3 Operações morfológicas

No trabalho realizado, foram utilizadas as operações morfológicas de processamento de imagens (HARALICK, 1987).

Estas operações são aplicadas especialmente em imagens binárias. Para realizá-las, deve-se utilizar um *elemento estruturante*, que é uma imagem pequena com um pixel denominado central ou âncora. O elemento

estruturante será varrido de modo que o pixel central passe por todos os pixels da imagem processada (HARALICK, 1987).

Na operação morfológica de *erosão*, o pixel correspondente ao pixel âncora será pintado da cor 1 caso todos os pixels correspondentes à região delimitada pelo elemento estruturante sejam 1. Caso contrário, ele é pintado de 0. Dessa forma, a erosão elimina partes da imagem referente aos pixels de valor 1, como mostrado na Figura 2.5. Essa Figura ilustra o procedimento de erosão do quadrado azul escuro pelo elemento morfológico circular, com âncora no ponto vermelho. O resultado da operação é o quadrado em ciano. A partir dessa figura, fica claro que a erosão retira parte das regiões erodidas.




Figura 2.5 – Visualização da operação de erosão

Fonte: (KESHET, 2008)

Uma aplicação da erosão é a eliminação de ruídos claros sobre fundo escuro, como mostrado na Figura 2.6. Isso ocorre porque ao passar o elemento estruturante sobre essas pequenas manchas, elas não conseguem cobrir o elemento todo, de modo que os pixels que correspondem ao ruído são removidos.

A operação morfológica de *dilatação* é similar à de erosão, com a diferença que o pixel correspondente à âncora será pintado de 1 caso ao menos 1 dos pixels correspondentes à região delimitada pelo elemento estruturante seja 1. Uma ilustração dessa operação está mostrada na Figura 2.7. Como na Figura 2.5, o elemento estruturante é o círculo, com ponto de âncora igual ao seu centro geométrico. Neste caso, o quadrado azul escuro está sendo dilatado, formando o quadrado ciano com cantos arredondados.




Figura 2.6 – Utilização da erosão para filtrar ruídos

Fonte: ([ABRISHAMI, 2015](#))




Figura 2.7 – Visualização da operação de dilatação

Fonte: ([KESHET, 2008](#))

Em ambas as operações descritas anteriormente, o tamanho da forma geométrica é modificado, seja aumentando sempre, como é o caso da dilatação, seja diminuindo sempre, como é o caso da erosão.

As próximas duas operações descritas tendem a manter as dimensões gerais das formas a que são aplicadas. Elas são combinação das operações de erosão e de dilatação.

A primeira delas, a *abertura*, é obtida pela erosão da figura seguida da dilatação da figura utilizando-se o mesmo elemento estruturante (HARALICK, 1987). A abertura tende a suavizar pontas da região considerada. Na Figura 2.8, pode-se ver uma operação de abertura com elemento circular e âncora no centro do círculo realizada sobre o quadrado azul escuro. A forma resultante é o quadrado com cantos arredondados em ciano. Uma das utilizações da abertura é quando se pretende os efeitos da dilatação, como a suavização de protuberâncias, sem uma mudança considerável nas dimensões gerais da figura.




Figura 2.8 – Visualização da operação de abertura

Fonte: (KESHET, 2008)

Por fim, o *fechamento*, é obtido pela dilatação da figura seguida da erosão da figura utilizando-se o mesmo elemento estruturante (HARALICK, 1987). O fechamento tende a suavizar entradas na região considerada. Na Figura 2.9 é ilustrado o fechamento em uma forma geométrica, indicada em azul escuro, pelo mesmo elemento estruturante circular das operações anteriores. A forma resultante é a mesma figura com a adição dos arredondamentos em ciano. Similarmente à abertura, uma das utilizações do

fechamento é para obter as características de suavização de entradas na figura geométrica sem alterar as dimensões gerais da mesma.




Figura 2.9 – Visualização da operação de fechamento

Fonte: (KESHET, 2008)

2.3.4 Espaço de cores

Para a captura de cores, o sistema visual humano possui dois tipos principais de células sensíveis à luz distribuídas pela retina. As células do tipo bastonete são sensíveis a qualquer tipo de luminosidade, independente da cor, elas são responsáveis por capturar o nível de luminosidade da imagem. Um indivíduo com apenas esse tipo de célula enxergaria as imagens em tons de cinza. As células do tipo cone existem em três tipos, x, y e z, que são sensíveis a diferentes comprimentos de onda eletromagnética, conforme Figura 2.10 (L'ÉCLAIRAGE, 1931).

Baseado no funcionamento da visão humana, foi-se estudada uma forma de representar cores de uma maneira que abrangisse todas as possíveis cores que um olho humano pode distinguir. Este espaço é conhecido como CIE 1931 (L'ÉCLAIRAGE, 1931).

Um diagrama bidimensional que representa as cores para uma luminância fixa pode ser visto na Figura 2.11. Nas bordas do diagrama, indicados em números azuis, estão as cores obtidas por ondas eletromagnéticas com um único comprimento de onda, indicado em nanômetros pelos números azuis. Todas as outras cores são visíveis a partir de misturas dos estímulos que chegam às células de tipo cone do olho humano.




Figura 2.10 – Resposta do olho humano para os cones de tipo x, y e z em função do comprimento de onda

Fonte: (CIE..., 2009)




Figura 2.11 – Diagrama de cores CIE 1931 com luminância fixa

Fonte: (CRIST, 2014)

Apesar de representar bem o que o olho humano vê, este espaço de cores não é o mais adequado para representar cores em dispositivos eletrônicos de visualização ou de impressões.

A existência de três tipos de cones sensíveis a diferentes faixas de comprimento de onda serviu de inspiração ao desenvolvimento de sensores de imagens passaram a utilizar respostas de três faixas de comprimento de onda para representar uma imagem colorida. O espaço de cores utilizado nas imagens obtidas por câmeras coloridas comuns é o *RGB*. Nele, cada cor é representada por três coordenadas, como representado na Figura 2.12 por um cubo de cores. São elas:

- R, representando a cor vermelha,
- G, representando a cor verde, e
- B, representando a cor azul.




Figura 2.12 – Espaço de cores RGB representadas em um cubo. Cada eixo ortogonal representa uma das coordenadas

Fonte: (HORVATH, 2008)

Para mostrar as cores em um monitor, por exemplo, a matriz de pontos luminosos mostrada na Figura 2.13 é selecionada de modo a distribuir essas três cores e iluminá-los conforme a coordenada do espaço de cores (também

chamada de canal da imagem) correspondente. Essa matriz de cores também é encontrada nos sensores ópticos RGB. Assim, combinando as cores do espaço RGB pode-se obter as cores do triângulo mostrado na Figura 2.14, contido no espaço de cores visíveis.




Figura 2.13 – Matriz de pontos coloridos observada tanto em monitores quanto em sensores ópticos RGB

Fonte: (BURNET, 2006)

Outro espaço de cores que foi utilizado neste trabalho é o espaço HSV (GONZALEZ; WOODS, 2002), cujas coordenadas são mostradas na Figura 2.15, com os canais:

- H, o matiz, que é uma medida do ângulo no cilindro de cores da Figura 2.15,
- S, a saturação, que é uma medida do quão longe a cor está da escala de cinza, e
- V, o valor ou luminância, que é uma medida da claridade da cor.

A transformação de coordenadas de HSV normalizadas, $(h, s, v) \in [0, 1]^3$, para o espaço $(r, g, b) \in [0, 1]^3$, é realizada conforme as regras estabelecidas na Equação 2.2 (GONZALEZ; WOODS, 2002).

$$(r, g, b) = \begin{cases} v \cdot (1, 1 + 6hs - s, 1 - s), & \text{se } 0 \leq h < \frac{1}{6} \\ v \cdot (s - (6h - 1)s, 1, 1 - s), & \text{se } \frac{1}{6} \leq h < \frac{1}{3} \\ v \cdot (1 - s, 1, 1 + (6h - 2)s - s), & \text{se } \frac{1}{3} \leq h < \frac{1}{2} \\ v \cdot (1 - s, s - (6h - 3)s, 1), & \text{se } \frac{1}{2} \leq h < \frac{2}{3} \\ v \cdot (1 + (6h - 4)s - s, 1 - s, 1), & \text{se } \frac{2}{3} \leq h < \frac{5}{6} \\ v \cdot (1, 1 - s, s - (6h - 5)s), & \text{se } \frac{5}{6} \leq h < 1 \end{cases} \quad (2.2)$$




Figura 2.14 – Sub-espaço de cores possíveis de serem representadas pelo padrão RGB

Fonte: (CRIST, 2014)

Nota: O ponto D65 indica o branco de 6500K




Figura 2.15 – Espaço de cores HSV representadas em um cilindro

Fonte: (HORVATH, 2010)

As vantagens do espaço de cores HSV sobre o espaço RGB é a maior facilidade de parametrização de uma cor dada pelo canal H. Pode-se ver na Figura 2.15 que, por exemplo, todos os tons esverdeados possíveis de serem representados neste espaço estão dentro de um setor bem definido do cilindro. No espaço RGB, algo similar não seria possível de ser feito escolhendo apenas um canal. Outro canal utilizado cuja informação foi utilizada neste trabalho é o V, devido à possibilidade de filtrar o tom de verde de algumas ervas não pertencentes à cultura em questão pelos valores do canal V.

A próxima seção apresenta um breve resumo dos trabalhos correlatos.

CAPÍTULO III

Trabalhos Correlatos

Nesta seção serão descritos alguns trabalhos correlatos que serviram justificaram algumas etapas da pesquisa e serviram para nortear os trabalhos realizados.

O trabalho feito em ([SØGAARD; OLSEN, 2003](#)) propõe algo similar ao que é proposto neste, mas ele usa imagens obtidas a partir de um trator em vez de um VANT, de forma que a perspectiva diferente permite que as linhas de plantio sejam aproximadas para linhas retas.

Além disso, ele se propõe a não utilizar a segmentação durante o processamento, substituindo-o pelo cálculo dos centros de gravidade de cada linha. A ideia do trabalho com isso era reduzir o custo computacional da detecção de plantas.

Entretanto, essa decisão obteve resultados que dependiam muito da quantidade de ervas daninhas. Por exemplo, em áreas em que havia um pouco de ervas daninhas do lado de uma linha, a linha encontrada era transladada na direção dessas plantas.

O artigo ([GARCÍA-SANTILLÁN, 2017](#)) não usa a mesma aproximação a uma reta para a imagem, o que mostra a necessidade de encontrar linhas de plantio que possuem curvatura. Ele também enxerga a dificuldade de isolar as plantas da plantação de outros tipos de planta.

Outro ponto interessante do artigo é que ele também inicia a resolução do problema com a segmentação do que é planta e o que não é.

Mas, também fazendo uso de imagens de trator, ele pressupõe algumas propriedades sobre a imagem, como por exemplo, que haverá linhas quase verticais na parte inferior da imagem, devido à montagem da câmera sobre o trator. É nesse ponto que a solução apresentada por esse trabalho não se aplica ao problema tratado neste. Neste, as linhas podem começar e

terminar em qualquer ponto da imagem, o que é um adicional de dificuldade.

O trabalho (LEE, 2000) busca, a partir de vários pontos, reconstruir uma curva cuja forma ou equação geral não é conhecida *a priori*. Isso indica uma dificuldade na identificação de curvas gerais. No entanto, esse trabalho possui como pré-requisito o fato de os pontos formarem uma única curva. As plantas nas imagens aéreas não estão previamente classificadas em linhas, de modo que esse trabalho aplicado repetidas vezes não resolveria o problema. Os locais das plantas considerados neste trabalho formam curvas diferentes, apesar de relacionadas. A solução apresentada neste trabalho produz essa classificação enquanto gera as curvas de saída.

Existem trabalhos anteriores sobre a identificação de formas predeterminadas, tais como linhas retas, arcos de círculos e elipses, e parametrizadas, como os coeficientes das retas e a excentricidade das elipses, formadas por pontos em uma imagem. Um desses estudos gerou a transformada de Hough (ILLINGWORTH; KITTLER, 1988). A transformada de Hough funciona tomando os pontos do espaço cartesiano de pixels e plotando-os em outro espaço, como por exemplo ρ e θ . As regiões de pontos mais comuns nesse espaço fornece os parâmetros das formas geométricas encontradas.

O estudo (BALLARD, 1981) mostra que é possível utilizar a transformada de Hough para identificar formas arbitrárias previamente definidas e parametrizadas. Um problema para a aplicação global deste algoritmo é que as linhas de plantio seguem formas imprevisíveis, que dependem da elevação do terreno, de obstáculos, e seguem formas arbitrárias desconhecidas *a priori*.

Estes trabalhos serviram para indicar possibilidades de tratamento do problema proposto e a aplicabilidade dos métodos utilizados em cada um foi considerada neste trabalho. A existência de trabalhos recentes que tratam da identificação de linhas de plantio em imagens feitas em tratores indicam a atualidade do tópico trabalhado. Entretanto, a possibilidade de trabalhar com imagens aéreas de resolução que possibilite identificar as linhas é um fator que muda as condições das imagens consideradas em (SØGAARD; OLSEN, 2003) e (GARCÍA-SANTILLÁN, 2017).

CAPÍTULO IV

Materiais e Métodos

Inicialmente, o algoritmo proposto segmenta a imagem e localiza pontos que indicarão por onde passarão as linhas a serem identificadas, como descrito na seção 4.1. Com esses pontos, serão analisadas as relações de distância entre os mesmos e serão encontradas algumas linhas que possuem ruídos e falhas, conforme descrito na seção 4.2. Essas linhas apresentam um padrão geral de conexões e direções, mas ainda não satisfazem a proposta do problema. Por fim, a seção 4.3 mostrará como essas linhas gerais foram suavizadas e pós-processadas de modo a formar o resultado final do algoritmo.

Este processo está ilustrado na Figura 4.1, que é um fluxograma geral do algoritmo proposto. A parte de segmentação, descrita na seção 4.1.1, é a primeira, seguida de localização dos centroides, na seção ??, em caso de sobreposição foliar, ou do algoritmo de área-ponto, descrito na seção 4.1.3. A sobreposição foliar ocorre quando não é possível, a partir da imagem, separar as copas das plantas, ou seja, as folhas de uma planta se sobrepõem às da vizinha. Depois disso, é feita uma busca de linhas gerais, explicada na seção 4.2, e, com as linhas encontradas, é feito um melhoramento, descrito na seção 4.3. Nas seções seguintes o fluxograma será explicado e algumas partes serão expandidas.

4.1 Localização de Plantas

Nesta seção, será visto como, no trabalho proposto, as imagens foram tratadas para se obter um conjunto de pontos que representam as plantas. Em imagens sem a sobreposição foliar, esse conjunto idealmente representa as localizações de cada planta. Em imagens com a sobreposição foliar, ainda deve ser possível identificar as linhas a partir dos pontos localizados.




Figura 4.1 – Fluxograma geral do algoritmo utilizado

Conforme o fluxograma da Figura 4.1, tais pontos serão utilizados como entrada para a parte da seção 4.2.

4.1.1 Segmentação

A entrada do algoritmo trabalhado é uma imagem aérea RGB ortorectificada de uma lavoura. Primeiramente, o algoritmo segmenta a imagem dada, de modo a identificar quais pixels são planta e quais pixels não são planta.

A imagem é convertida do espaço de cores RGB, onde os valores do pixel são as intensidades das componentes vermelho (*R*), verde (*G*) e azul

(B), para o espaço de cores HSV. Nesse espaço, as componentes são matiz (H), saturação (S) e valor (V), como já mostrado na Figura 2.15. Neste espaço de cores, é mais natural identificar a cor predominante do pixel e segmentar a imagem a partir do verde.

Para reduzir ruído, os canais H e V passam por uma erosão e depois por uma dilatação. Os elementos estruturantes dessas operações são círculos de raio fornecido pelo usuário. A escolha do círculo é devido ao fato de as plantas individuais possuírem formato arredondado ao serem fotografadas de cima. O objetivo da erosão é eliminar ruídos, principalmente de pequenas plantas e folhas que esteja na entrelinha. O objetivo da dilatação é unir manchas que fazem parte da mesma planta e foram separadas na erosão anterior, no caso da imagem sem sobreposição foliar. No caso de imagens com sobreposição foliar, o objetivo da dilatação aqui é unir as manchas de linhas e torná-las menos irregulares para aplicação do sub-algoritmo de área-ponto, descrito na seção 4.1.3.

Para cada um dos canais H e V , é aplicado um limiar do que é aceitável como valor possível de planta e o que não é. Os canais são unidos utilizando o operador lógico E , dado que a inadmissibilidade de um pixel de ser planta por um dos canais implica que o pixel como um todo é inadmissível de ser considerado como planta. Por padrão, o limiar utilizado é dado pelo algoritmo de Otsu (OTSU, 1975).

Com a imagem segmentada, a etapa seguinte atribui pontos representativos dessa segmentação. O algoritmo toma dois caminhos diferentes para o caso em que as plantas possuem sobreposição foliar, como na Figura 4.4 e para o caso em que elas não possuem sobreposição foliar, como na Figura 4.2.

4.1.2 Centroides

No caso em que as plantas não possuem sobreposição foliar, as regiões brancas obtidas pelas etapas anteriores são aproximadamente equivalentes ao local de cada planta na lavoura. Um exemplo de segmentação de imagem sem sobreposição foliar está na Figura 4.3. Então aplica-se o crescimento de região por conectividade-4. A conectividade-4 é quando um *pixel* está ligado a seus 4 vizinhos ou possui conectividade-4 com um de seus 4 vizinhos, definida recursivamente.

Para isso, é feito o crescimento de região. O crescimento de região é feito utilizando o seguinte método: dado uma fila com um pixel branco. Se



Figura 4.2 – Imagem RGB original sem sobreposição foliar




Figura 4.3 – Imagem segmentada sem sobreposição foliar



Figura 4.4 – Imagem RGB original com sobreposição foliar




Figura 4.5 – Imagem segmentada com sobreposição foliar

o primeiro pixel da fila é branco, acrescentam-se seus 4 vizinhos à fila, e conta-se esse pixel como parte da região. Repete-se o procedimento até a fila ficar vazia.

Cada região assim obtida passa a ser representada por um ponto. Esse ponto é o centroide da região. Como o caso de não sobreposição implica em apenas uma planta por região, o centroide é um ponto que representa bem a localização das plantas.

4.1.3 Área-ponto

Para o caso em que as plantas possuem sobreposição foliar, o método utilizado na seção anterior não fornece resultados satisfatórios. Neste caso, muitas vezes a linha de saída era perpendicular às linhas reais de plantio, já que os centroides de diferentes regiões eram aproximadamente colineares. Utilizou-se um método que encontra vários pontos que representam uma área alongada, como as regiões vistas na Figura 4.5.

Nesse caso, toma-se o maior círculo que pode ser encaixado na região e adiciona-se o centro desse círculo aos pontos representativos da região, como pode ser visto no fluxograma da Figura 4.6. Isso é computacionalmente possível de ser feito utilizando-se a transformada de distância. A Figura 4.6 mostra o fluxograma do algoritmo de área-ponto, composto de uma transformada de distância, a partir de onde é encontrado o *pixel* com maior distância dos *pixels* pretos. A partir daí, se a distância for maior que o raio mínimo, adiciona-se esse ponto ao conjunto de saída do algoritmo e retira-se o círculo com esse raio da região. Caso contrário, o algoritmo área-ponto termina. Nela, o valor de cada pixel branco é alterado de modo que ele represente a distância até o pixel preto mais próximo. Pode-se ver, na Figura 4.7, que os pixels mais distantes da borda da região branca possuem valores maiores, ou seja, são mais claros. A partir da imagem transformada, a localização do pixel de maior valor é o centro do círculo de maior raio que pode ser encaixado dentro da região branca e o seu valor é igual ao raio desse círculo. Depois de encontrado, pinta-se esse círculo de preto de modo que ao repetir o procedimento o círculo seguinte encontrado não sobreponha círculos encontrados anteriormente. Então repete-se até que o raio do maior círculo seja menor que um limiar especificado. A Figura 4.8 mostra o resultado da aplicação desse algoritmo em uma região com sobreposição. Nela, os círculos vermelhos são todos os círculos de raio maior que 6 pixels que podem ser encaixados na região branca da figura, enquanto os pontos azuis são os centros desses círculos. A saída desta etapa do algoritmo, ou seja, os

pontos que representam bem a área branca são os pontos azuis da figura.




Figura 4.6 – Fluxograma do algoritmo de área-ponto




Figura 4.7 – Transformada de distância de uma região similar à da Figura 4.8

Na Figura 4.8, observa-se que mesmo que duas linhas estejam com pequena sobreposição entre si e tenham sido consideradas pelo algoritmo como parte da mesma região, os pontos que as representam são claramente pouco influenciados pela entrada com mais de uma linha.




Figura 4.8 – Visualização do algoritmo de área-ponto

4.2 Busca de Linhas Gerais

A entrada desta parte é uma imagem pré-processada com um conjunto de locais com pontos de plantas. Esses pontos inicialmente são dados como as coordenadas x e y no sistema de coordenadas da imagem. Com o desenvolvimento do algoritmo, essas coordenadas passaram a ser a latitude e a longitude das plantas em questão.

Os processos para obter as linhas gerais estão mostrados no fluxograma da Figura 4.9. Ele mostra que os pontos encontrados pela etapa de segmentação serão buscados para encontrar o ponto e a direção do ponto mais próximo, a partir das quais será determinada a direção predominante local no ponto, que será usada para conectar pontos vizinhos de linhas. Ao final, serão descartadas ligações em excesso para que a saída não seja um grafo geral, mas sim um grafo com grau máximo 2. Em cada subseção será descrita, com mais detalhes, cada etapa deste fluxograma.

4.2.1 Selecionar direção do ponto mais próximo

Para cada ponto B da entrada, o algoritmo encontra o ponto P , o mais próximo de B . Com essa informação, ele calcula e armazena a direção $\overrightarrow{BP}$, utilizando a fórmula da Equação (4.1).

$$\text{atan2}(\Delta y, \Delta x) \quad (4.1)$$

Essa informação pode ser vista na Figura 4.10 e será utilizada na seção 4.2.2.

4.2.2 Selecionar direção predominante

O algoritmo, nesta parte, tenta determinar as direções gerais das linhas. Para tanto, a primeira proposta é tomar a direção de cada ponto B para o ponto mais próximo P . O resultado dessa etapa em uma das imagens de teste está mostrado na Figura 4.10. Nessa figura, cada ponto B da entrada possui uma seta saindo em direção ao seu vizinho mais próximo P .



Figura 4.9 – Fluxograma do algoritmo de buscar linhas gerais




Figura 4.10 – Ponto mais próximo P de cada ponto base B

Nota: As setas saem de B e apontam para P

Apesar de normalmente o ser, o ponto mais próximo nem sempre é um bom indicador da direção da linha de plantio. Para resolver este problema, pontos em uma região estatisticamente significativa são considerados. O método adotado para fazê-lo é tomar os N pontos mais próximos de um ponto base B e usá-los para escolher uma direção representativa, como mostrado na Figura 4.11, onde N é um parâmetro da ordem de 20 a 40 pontos.




Figura 4.11 – Exemplo de pontos vizinhos e suas direções

Nota: Cada cor de seta representa uma direção discretizada diferente, conforme Figura 4.13

Para esses N pontos mais próximos, tenta-se inferir a direção predominante. Em uma plantação ideal, a distância d entre duas plantas vizinhas na mesma linha é menor do que a distância D entre duas linhas de plantio, como mostrado na Figura 4.12, de modo que os pontos de entrada são suficientes para determinar as linhas. Esta é a razão pela qual a entrada deste algoritmo é apenas o conjunto de pontos. Portanto, a maioria dos pontos B devem possuir seu ponto mais próximo na direção $\Theta(B)$ da linha de plantio. A maneira escolhida para encontrar esta direção é criando 9 direções lógicas θ_i , como mostrado na Figura 4.13 e contando quantos dos N pontos têm seu vizinho mais próximo na direção θ_i para cada $i \in \{0, 1, \dots, 8\}$. A escolha de 9 direções foi feita com base em testes feitos durante o desenvolvimento com imagens de café. A direção com mais incidências $\Theta(B) = \theta_i$ é a direção escolhida para localizar os pontos a serem conectados. A tabela 4.1 mostra uma distribuição típica observada dessas direções, onde no caso $\Theta(B) = \theta_5$.




Figura 4.12 – Parte da imagem aérea de uma linha de plantio. A distância D entre duas linhas é maior que a distância d entre duas plantas adjacentes na mesma linha




Figura 4.13 – Discretização e enumeração das direções

Tabela 4.1 – Exemplo de distribuição de direções para a Figuras 4.11 e 4.13

Direção θ_i	Contagem	Frequência
$i = 0$	1	4%
1	1	4%
2	1	4%
3	1	4%
4	1	4%
5	18	72%
6	1	4%
7	1	4%
8	0	0%

4.2.3 Conectar pontos vizinhos de linha

Para cada ponto B , após encontrar a direção predominante $\Theta(B)$ centrada em B , o algoritmo procura por pontos em um retângulo cujo eixo maior está nessa direção. Então, em cada metade do retângulo, o algoritmo conecta o ponto B ao ponto mais próximo nessa direção, como na Figura 4.14. Assim, cada ponto será origem de uma ligação a no máximo dois outros pontos. Note que o ponto pode ser destino de outros pontos, o que será tratado na seção 4.3.3.




Figura 4.14 – Retângulo mostrando os pontos candidatos à ligação

Nesta proposta, um retângulo porque se parece uma linha e possui tolerância para o caso de a linha esperada ser uma curva. Como observado na Figura 4.14, uma dimensão muito grande pode levar à conexão a outra linha dentro de uma região curvada. A dimensão menor é escolhida de modo que pontos que estão muito próximos mais provavelmente estarão na mesma linha. Isso ajuda muito no caso em que a linha é muito irregular e um ponto suficientemente próximo com direção $\theta_i \neq \Theta(B)$, porque é muito improvável, dada a distribuição de pontos, que pontos suficientemente próximos sejam parte de linhas diferentes.

Este método apresentado ignora alguns pontos que poderiam estar na mesma linha. Isso é resolvido na etapa seguinte do algoritmo, principalmente na parte descrita na seção 4.3.4, onde linhas não-filtradas são cortadas e unidas entre si para gerar a saída final do algoritmo. Este método também conecta alguns pontos a mais de um ponto, permitindo uma topologia genérica de grafo. A próxima seção mostra como o algoritmo trata essa configuração.

4.2.4 Descartar ligações em excesso

Para o caso em que um ponto é conectado a mais de dois pontos, o algoritmo busca e tenta resolver o problema para todos esses pontos.

Então, para cada ponto B que está conectado aos pontos $P_i, i \in \{1, \dots, n\}$, $n > 2$, ele busca o par (i, j) com $i, j \in \{1, \dots, n\}$ tais que o ângulo $\angle P_i B P_j$ é maximizado. Com isso, ele desconecta todos os pontos $P_k, k \in \{1, \dots, n\}$, $k \neq i, j$.

Com isso, obtém-se conjuntos disjuntos que representam, aproximadamente, linhas. As seções seguintes do algoritmo são filtros, isto é, tomam um conjunto de linhas como entrada e retornam um conjunto de linhas como saída.

4.3 Melhorar Linhas Encontradas

Nas imagens estudadas, a segmentação produz alguns pontos que não são plantas da lavoura. Podem ser plantas daninhas, manchas, ou até mesmo outros tipos de ruído que não foram filtrados pela erosão morfológica. Mesmo que o problema de ruídos tenha sido tratado na segmentação, esta parte deve tratar coisas que ainda ficaram de fora desse tratamento, como é o caso das ervas daninhas.

O fluxograma da Figura 4.15 mostra as etapas utilizadas para melhorar os resultados iniciais encontrados. No decorrer desta seção, estas etapas serão mostradas em detalhes. Primeiramente, o fluxograma mostra que os pontos das linhas serão varridos para buscar e eliminar ângulos agudos, como explicado na subseção 4.3.1, depois alguns finais de linhas serão cortados, como visto na subseção 4.3.2. As linhas pequenas, provavelmente formadas por plantas daninhas, serão descartadas, como mostrado na subseção 4.3.3. Uma parte importante é a conexão de linhas parecidas com polinômios, mostrada na subseção 4.3.4, seguida de outra suavização, conforme subseção 4.3.5.




Figura 4.15 – Fluxograma do algoritmo de melhorar as linhas encontradas

4.3.1 Suavizar ângulos agudos

Um indicador de que o ponto não é parte de uma linha é o fato de esse ponto ser o centro B de um ângulo de medida pequena $\angle ABC$, como mostrado na Figura 4.16. O algoritmo realiza uma busca por tais ângulos em todas as linhas e elimina os pontos centrais dos ângulos que não satisfazem a condição de medida suficientemente grande, já que tais pontos provavelmente não fazem parte da linha de plantio. O algoritmo proposto utiliza $\frac{2\pi}{3}$ rad como ângulo limite para este critério.

4.3.2 Cortar finais de linhas

Outro indicativo de que o ponto não faz parte da linha de plantio é que ele seja o último ponto de uma linha encontrada e a tendência de direção




Figura 4.16 – Um ângulo agudo a ser filtrado. O ponto B é um ponto espúrio

dessa linha é muito diferente da direção desenhada por esse ponto. Com maior formalismo matemático, sejam os pontos L o último ponto da linha encontrada, S o penúltimo ponto, e B o n -ésimo ponto da linha (como na Figura 4.17, onde $n = 4$), o algoritmo elimina o ponto L se

$$\angle SBL < \alpha, \quad (4.2)$$

onde α foi escolhido para ser $\pi/36$ rad e n foi escolhido como 4.




Figura 4.17 – Um ponto espúrio no final de uma linha. $\angle SBL$ é o critério para eliminá-lo

4.3.3 Descartar linhas pequenas

Algumas linhas possuíam muito poucos pontos para serem consideradas como linhas de fato significativas. Algumas delas podem ser formadas até mesmo por linhas de plantas daninhas, e o tamanho da linha é muito pequeno para a significância estatística da classificação. Portanto, nesta etapa, linhas formadas por menos de 4 pontos foram descartadas da saída.

4.3.4 Conectar linhas parecidas com polinômios

Esta etapa é muito importante para o bom funcionamento do algoritmo, porque existem falhas de plantio (ver Figura 4.18) entre plantas da mesma linha. Mesmo com as falhas, as plantas ainda deveriam ser consideradas como parte da mesma linha. O algoritmo processa cada linha, e para cada uma delas ele segue o procedimento de decisão de conectar ou não a linha em processamento e qual a outra linha a ser conectada, como mostrado na Figura 4.19.



Figura 4.18 – Falhas de plantio

A ideia por trás do processo da Figura 4.19 é buscar as linhas vizinhas e calcular os pontos análogos no meio das falhas, como na Figura 4.20. Os hexágonos da Figura 4.19 indicam que um sub-algoritmo, iniciado pela seta saindo da direita, é feito para cada elemento do conjunto indicado pelo hexágono. A cada final de linha E , é buscado um ponto próximo B dentro de 20 pontos ou outros à escolha do usuário do algoritmo, de modo que para cada ponto P na mesma linha de B é salvo o ponto $N = E + \overrightarrow{BP}$ e a distância deste ponto ao seu adjacente na linha. Com isso, é calculada a distância média A das distâncias entre pontos adjacentes. Depois disso, a Figura 4.19 mostra que é feita uma regressão polinomial nos pontos S salvos anteriormente, e, para cada ponto extrapolado X , com distância $A/2$ do ponto extrapolado na iteração anterior, dentro dos limites da imagem processada, é verificado se existe uma linha L com ponto distante de X menor que a distância $A/2$. Em caso verdadeiro na primeira das iterações do sub algoritmo indicado pelo hexágono, as linhas são conectadas.

Isso fica claro ao observar o paralelogramo formado pelos pontos B , P_i , E e $N_i = E + \overrightarrow{BP_i} = P_i + \overrightarrow{BE}$. Na Figura 4.21, pode-se ver os pontos calculados




Figura 4.19 – Fluxograma da decisão de conectar linhas

que continuam a partir do ponto marcado em vermelho. Esses pontos foram calculados a partir de pontos correspondentes nas linhas rosadas. Como esse cálculo toma várias linhas vizinhas e gera muitos pontos próximos, a proposta é fazer uma espécie de análise estatística utilizando os pontos calculados.




Figura 4.20 – Paralelogramos utilizados para prever possíveis pontos de continuação

O primeiro parâmetro estatístico tomado é a distância média $\bar{A}$ entre pontos adjacentes nas linhas vizinhas. Essa distância $\bar{A}$ deve ser próxima da média da distância entre plantas na mesma linha. Então o algoritmo executa uma regressão polinomial de grau 2 utilizando os pontos gerados e salvos em

um conjunto R . O eixo horizontal x da regressão é paralelo à reta formada pelo primeiro e último pontos da linha em consideração. A escolha dos eixos é para evitar que os pontos tendam a formar uma linha aproximadamente paralela ao eixo vertical y . O eixo y é tomado como normal ao eixo x .

A cada ponto $P_i \in R$ é atribuído um peso na regressão, de valor $\exp\left(\frac{-z^2}{2}\right)$, onde $z = \frac{\text{dist}(P_i, E)}{\bar{A}}$. Esse peso é utilizado para evitar grandes influências de pontos que estão muito longe do ponto E original, e priorizar pontos cuja localização está próxima de E .

Com os parâmetros da curva polinomial calculados, o algoritmo busca, em passos discretos, extrapolar a linha original e encontrar uma outra linha l preexistente que seja suficientemente próxima de um dos pontos calculados na extrapolação. Cada passo da extrapolação é um ponto com distância $\frac{\bar{A}}{2}$ do anterior. A partir desse passo, o algoritmo tenta encontrar um ponto de uma linha preexistente com distância menor que $\frac{\bar{A}}{2}$ do ponto calculado. Se tal ponto existe em uma linha l , o algoritmo para de criar passos da extrapolação, conecta as duas linhas e continua para refazer a consideração em outras linhas.

Na Figura 4.21, a linha verde foi corretamente encontrada para ser a continuação da linha marcada com o ponto vermelho utilizando este método. Os pontos azuis da Figura 4.21 são os pontos do conjunto R , de onde foi feita a regressão.

4.3.5 Suavizar ângulos pequenos

Ao final do processo de conexões, o algoritmo descarta pontos centrais de ângulos pequenos novamente, mas desta vez o objetivo é suavizar as linhas de saída. O parâmetro de limiar de ângulo aqui é o mesmo $2\pi/3$ rad.




Figura 4.21 – Estimativa dos possíveis pontos de continuação ao estender o ponto vermelho da linha com pontos análogos das linhas marcadas em rosa. A estimativa prediz corretamente a linha verde como a continuação da linha com o ponto vermelho

CAPÍTULO V

Resultados e Discussões

5.1 Resultados

A validação foi realizada com 20 imagens diferentes, com imagens das seguintes culturas: café com sobreposição foliar, café sem sobreposição foliar, cana-de-açúcar, laranja, e soja sem sobreposição foliar. O processo de segmentação para identificar os pontos variou conforme a existência ou não da sobreposição foliar.

As imagens foram obtidas com o VANT SX2, da Figura 2.2, a uma altitude variável entre 100 e 150 metros, com uma velocidade em relação ao ar de aproximadamente 15m/s. O plano de voo foi ajustado para cobrir toda a área de interesse. As imagens utilizadas foram todas capturadas com uma câmera RGB. Todas as imagens foram obtidas durante o dia e sem coberturas de nuvens.

Várias características e configurações foram incluídas nas imagens validação como forma de verificar certa robustez no algoritmo, como obstáculos, linhas em diferentes direções, estradas de terra, plantas daninhas, árvores no entorno da lavoura, árvores dentro da lavoura, postes de transmissão de energia elétrica, gramíneas próximas à lavoura, resoluções diferentes e sombra.

Para a validação as linhas resultantes foram medidas por comprimento. Foram identificadas manualmente as partes das linhas reais de plantio que deveriam ter sido consideradas como linhas mas não fizeram parte da saída do algoritmo (falso negativo) e as partes das linhas retornadas pelo algoritmo que estavam fora de uma linha de plantio real (falso positivo).

O verdadeiro positivo, ou seja, as linhas que fizeram parte da saída do algoritmo e que também faziam parte das linhas reais na imagem, também

foi medido manualmente em comprimento.

Todo o restante da imagem foi considerado como verdadeiro negativo, então nenhuma medida de comprimento foi realizada.

O método escolhido para avaliar os resultados foi o *F-1 score*, conforme Equação (5.1) (RIJSBERGEN, 1974), porque esse método não depende dos valores de falso negativo.

$$\frac{2}{\frac{VP}{VP+FP} + \frac{VP}{VP+FN}} \quad (5.1)$$

Os resultados e os dados para calcular o *score* estão na tabela 5.1.

Tabela 5.1 – Percentagens dos resultados utilizando 20 imagens diferentes. A tabela mostra as taxas de verdadeiro positivo, falso positivo e falso negativo e o resultado do *score* F-1

#	Cultura	VP%	FP%	FN%	F1
01	Cana-de-açúcar	92.16%	1.43%	6.41%	.959
02	Cana-de-açúcar	86.05%	2.92%	11.03%	.925
03	Laranja	79.71%	7.39%	12.89%	.887
04	Café	98.27%	0.00%	1.73%	.991
05	Café	93.48%	1.95%	4.57%	.966
06	Café	95.45%	3.14%	1.40%	.977
07	Café	96.86%	0.48%	2.66%	.984
08	Café	93.22%	4.85%	1.93%	.965
09	Café	97.66%	0.00%	2.34%	.988
10	Café	97.59%	1.02%	1.39%	.988
11	Café	85.67%	7.01%	7.31%	.923
12	Café	89.14%	2.71%	8.15%	.943
13	Café	98.41%	0.00%	1.59%	.992
14	Café	90.63%	2.87%	6.50%	.951
15	Soja	95.40%	0.00%	4.60%	.976
16	Soja	99.28%	0.00%	0.72%	.996
17	Café	92.88%	4.28%	2.84%	.963
18	Café	92.90%	2.07%	5.03%	.963
19	Café	98.49%	0.00%	1.51%	.992
20	Café	95.08%	0.00%	4.92%	.975

Após os testes foi possível concluir a qualidade dos resultados atingidos com o método de avaliação proposto ($F1 = 0.965$).

5.2 Discussões

Apesar de o algoritmo ter sido desenvolvido com a cultura de café em mente, ele foi testado com diferentes culturas e diferentes configurações das

plantações de café, tanto com sobreposição foliar quanto sem sobreposição.

A principal fonte de falsos negativos foram finais de linhas que não foram estendidos pelo algoritmo. De fato, o algoritmo desenvolvido não cobre estes casos. Outra fonte de falsos negativos foram algumas falhas que não foram detectadas.

A principal fonte de falsos positivos foram linhas que conectavam às vizinhas, levando a partes de linhas detectadas que não correspondiam a nenhuma linha de plantio real. Outra causa importante de falsos positivos foram linhas fora da lavoura. Esse problema é resolvido ao eliminar as regiões da imagem que não fazem parte da lavoura antes de passar a imagem como entrada para o algoritmo.

Nas Figuras 5.1a e b são apresentadas as linhas de saída do algoritmo em vermelho sobre as imagens de entrada. Na Figura 5.1a é apresentada a robustez do algoritmo no caso em que a imagem de entrada possui dois talhões diferentes. Nela também são apresentados alguns casos de falsos positivos (no caso, linhas que conectam às vizinhas) e de falsos negativos (linhas que não extrapolam para o final da imagem). Na Figura 5.1b é apresentado quão bem o algoritmo executou no caso de falhas nas linhas, assim como exemplos de falsos positivos devido à existência de plantas daninhas.




Figura 5.1 – Resultado do processamento: a) de cana-de-açúcar (#01) com dois talhões diferentes na mesma imagem; b) de café com sobreposição (#05) com algumas falhas de plantio corretamente continuadas

CAPÍTULO VI

Conclusão e trabalhos futuros

6.1 Conclusão

O algoritmo atendeu às expectativas propostas na introdução, com certa robustez a obstáculos, como pôde ser visto na Tabela 5.1.

O algoritmo proposto para encontrar as linhas se inicia pela segmentação da imagem RGB e localização de pontos de referência para a identificação de linhas. Com esses pontos, o algoritmo identifica as direções predominantes na região e inicia a ligá-los, formando linhas. As linhas iniciais mostravam uma tendência da direção correta, mas apresentavam vários problemas devido, principalmente, a ruídos e a falhas de plantio. Para resolver esses problemas, as linhas são filtradas de modo que o resultado seja mais adequado à aplicação que for utilizá-las.

Apesar do score F1 ter sido alto, de 0.965, foi notada uma dependência da técnica de segmentação utilizada. Este trabalho utilizou duas técnicas para encontrar os pontos a partir da segmentação. Os parâmetros padrão de segmentação para este trabalho foram dados pelo método de Otsu (OTSU, 1975). Como imaginado, esse método não foi efetivo para todas as situações. Por exemplo, no resultado #03, para a laranja, a imagem era toda em tons de verde devido às espécies que cobriam o solo. Mesmo assim, o score F1 foi 0.88.

Foram superados vários possíveis problemas com as técnicas de filtragem de linhas. No caso representado na Figura 5.1a, em que linhas em diferentes talhões foram corretamente identificadas, mostra a capacidade do algoritmo desenvolvido de tratar diferentes direções locais apropriadamente. Além disso, o caso da Figura 5.1b, em que as linhas foram corretamente continuadas por regiões sem planta até chegarem na plantação correspondente,

mostra a qualidade do algoritmo de ligação de linhas da seção 4.3.4.

O método proposto diferencia-se de outros trabalhos correlatos na possibilidade de identificar linhas a partir de imagens aéreas. Ele também se propõe a identificar as linhas mesmo com a existência de falhas de plantio, o que o torna viável em uma possível aplicação automática de identificação de falhas de plantio.

6.2 Trabalhos Futuros

Para uma aplicação completamente automática, mais investigações devem ser feitas em relação à automatização da segmentação e a geração dos pontos representativos de área.

Este trabalho poderá servir como base para diversos outros trabalhos na área de processamento de imagens na agricultura. Ele abre possibilidades para: encontrar falhas de plantio, que é o principal objetivo após a finalização deste trabalho, estimativa de produção, contagem e estimativa do número de plantas, planejamento e projeto de plantio, georreferenciamento de linhas de plantio para máquinas sem piloto, entre outros.

Referências

- ABRISHAMI, H. Adaptive video-based vehicle classification technique for monitoring traffic. p. 19, jun 2015. Disponível em: <https://www.researchgate.net/publication/305222104_Adaptive_Video-based_Vehicle_Classification_Technique_for_Monitoring_Traffic>. Citado na página 10.
- BALLARD, D. H. Generalizing the hough transform to detect arbitrary shapes. *Pattern Recognition*, v. 13, n. Issue 2, p. 111–122, 1981. Doi:10.1016/0031-3203(81)90009-1. Citado na página 20.
- BLACKMER, T. M.; SCHEPERS, J. S. Aerial photography to detect nitrogen stress in corn. *Journal of Plant Physiology*, v. 148, p. 440–444, 1996. Doi:10.1016/S0176-1617(96)80277-X. Citado na página 1.
- BREU, H.; GIL, J. J.; KIRKPATRICK, D.; WERMAN, M. Linear time euclidean distance transform algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 17, n. Issue 5, p. 48–62, may 1995. Doi:10.1109/34.391389. Citado na página 8.
- BRISCO, B.; BROWN, R. J.; HIROSE, T. et al. Precision agriculture and the role of remote sensing: A review. *Journal canadien de télédétection*, v. 24, n. Issue 3, 1998. Doi:10.1080/07038992.1998.10855254. Citado na página 3.
- BURNET, C. M. L. *Bayer pattern on sensor*. 2006. Disponível em: <https://commons.wikimedia.org/wiki/File:Bayer_pattern_on_sensor.svg>. Citado na página 15.
- CHAERLE, L.; STRAETEN, D. V. D. Seeing is believing: imaging techniques to monitor plant health. *Biochimica et Biophysica Acta (BBA) — Gene Structure and Expression*, v. 1519, n. Issue 3, p. 153–166, jun 2001. Doi:10.1016/S0167-4781(01)00238-X. Citado na página 4.
- CIE 1931 XYZ Color Matching Functions. 2009. Disponível em: <https://en.wikipedia.org/wiki/File:CIE_1931_XYZ_Color_Matching_Functions.svg>. Citado na página 13.
- CRIST, R. Taking a closer look at color-changing leds. 2014. <https://www.cnet.com/news/taking-a-closer-look-at-color-changing-smart-led-bulbs>. Citado 2 vezes nas páginas 13 e 16.

- GARCÍA-SANTILLÁN, I.; GUERRERO, J. M.; MONTALVO, M.; PAJARES, G. Curved and straight crop row detection by accumulation of green pixels from images in maize fields. *Precision Agriculture*, jan 2017. Doi:10.1007/s11119-016-9494-1. Citado 2 vezes nas páginas 19 e 20.
- GONZALEZ, R. C.; WOODS, R. E. Digital image processing. *Upper Saddle River, NJ*, Prentice Hall, 2002. Citado 2 vezes nas páginas 7 e 15.
- HARALICK, R. M.; STERNBERG, S. R.; ZHUANG, X. Image analysis using mathematical morphology. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-9, n. Issue 5, p. 532–550, jul 1987. Doi:10.1109/TPAMI.1987.4767941. Citado 3 vezes nas páginas 8, 9 e 11.
- HORVATH, M. *RGB color solid cube*. 2008. Disponível em: <https://en.wikipedia.org/wiki/File:RGB_color_solid_cube.png>. Citado na página 14.
- HORVATH, M. *HSV color solid cylinder*. 2010. Disponível em: <https://commons.wikimedia.org/wiki/File:HSV_color_solid_cylinder_alpha_lowgamma.png>. Citado na página 16.
- ILLINGWORTH, J.; KITTLER, J. A survey of the hough transform. *Computer Vision, Graphics, and Image Processing*, v. 44, n. Issue 1, p. 87–116, oct 1988. Doi:10.1016/S0734-189X(88)80033-1. Citado na página 20.
- KATAOKA, T.; KANEKO, T.; OKAMOTO, H.; HATA, S. Crop growth estimation system using machine vision. In: *Advanced Intelligent Mechatronics*. [S.l.: s.n.], 2003. Doi:10.1109/AIM.2003.1225492. Citado na página 1.
- KESHET, R. *Topological skeleton*. 2008. Disponível em: <https://en.wikipedia.org/wiki/User:Renatokeshet/Topological_skeleton>. Citado 4 vezes nas páginas 9, 10, 11 e 12.
- LAGERSTROM, R.; BUCKLEY, M. An attribute weighted distance transform. *Pattern Recognition Letters*, v. 33, n. Issue 16, p. 2141–2147, dec 2012. Doi:10.1016/j.patrec.2012.07.001. Citado na página 8.
- LALIBERTE, A. S.; WINTERS, C.; RANGO, A. A procedure for orthorectification of sub-decimeter resolution imagery obtained with an unmanned aerial vehicle (uav). In: *Proc. ASPRS Annual Conf.* [S.l.: s.n.], 2008. p. 08–047. Citado na página 5.
- LEE, I.-K. Curve reconstruction from unorganized points. *Computer Aided Geometric Design*, v. 17, n. Issue 2, p. 161–177, feb 2000. Doi:10.1016/S0167-8396(99)00044-8. Citado na página 20.
- L'ÉCLAIRAGE, C. I. de. Commission internationale de l'Éclairage proceedings. *Cambridge University Press*, 1931. Citado na página 12.
- MCBRATNEY, A. B.; PRINGLE, M. J. Estimating average and proportional variograms of soil properties and their potential use in precision agriculture. *Precision Agriculture*, v. 1, n. Issue 2, p. 125–152, sep 1999. Doi:10.1023/A:1009995404447. Citado na página 3.

OTSU, N. A threshold selection method from gray-level histograms. *Automatica*, v. 11, n. 285-296, p. 23–27, 1975. Citado 2 vezes nas páginas 23 e 45.

RIJSBERGEN, C. J. van. Foundation of evaluation. *Journal of Documentation*, v. 30, n. Issue 4, p. 365–373, dec 1974. Doi:10.1108/eb026584. Citado na página 42.

ROUSE, F. J.; HAAS, R. H.; SCHEEL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with erts. *3rd Earth Resource Technology Satellite (ERTS) Symposium Proceedings*, v. 1, p. 48–62, 1974. <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19740022592.pdf>. Citado na página 4.

SANKARAN, S.; KHOT, L. R. et al. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*, v. 70, p. 112–123, oct 2015. Doi:10.1016/j.eja.2015.07.004. Citado na página 1.

SØGAARD, H. T.; OLSEN, H. J. Determination of crop rows by image analysis without segmentation. *Computers and Electronics in Agriculture*, v. 38, n. Issue 2, p. 141–158, feb 2003. Doi:10.1016/S0168-1699(02)00140-0. Citado 2 vezes nas páginas 19 e 20.

VALAVANIS, K. P.; VACHTSEVANOS, G. J. *Handbook of unmanned aerial vehicles*. [S.l.]: Springer Publishing Company, Incorporated, 2014. Citado na página 6.

VEIGA, A.; OLIVEIRA, S. d.; SOUZA, C. de; AGUIAR, V. d. A. et al. Formação de mudas de coffea arabica l. cv rubi utilizando sementes e frutos em diferentes estádios de desenvolvimento. In: IN: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 3., 2003, PORTO SEGURO. RESUMOS... BRASÍLIA, DF: EMBRAPA CAFÉ, 2003. *Embrapa Café-Resumo em anais de congresso (ALICE)*. [S.l.], 2003. Citado na página 2.

WHELAN, B. M.; MCBRATNEY, A. B. The “null hypothesis” of precision agriculture management. *Precision Agriculture*, v. 2, n. Issue 3, p. 265–279, nov 2000. Doi:10.1023/A:1011838806489. Citado na página 3.

ZHANG, C. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, v. 13, n. Issue 6, p. 693–712, dec 2012. Doi:10.1007/s11119-012-9274-5. Citado na página 4.

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture—a worldwide overview. *Computers and Electronics in Agriculture*, v. 36, n. Issues 2–3, p. 113–132, nov 2002. Doi:10.1016/S0168-1699(02)00096-0. Citado na página 3.