

UNIVERSIDADE FEDERAL DO RIO GRANDE  
CENTRO DE CIÊNCIAS COMPUTACIONAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO  
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO

Dissertação de Mestrado

**Identificação de linhas de plantação em ambiente  
não controlado**

Felipe Bayer Weber

Orientador: Prof. Dr. Paulo Lilles Jorge Drews-Jr

Rio Grande, 2020

**MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO RIO GRANDE  
CENTRO DE CIÊNCIAS COMPUTACIONAIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO  
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO**

**DISSERTAÇÃO DE MESTRADO**

Identificação de linhas de plantação em ambiente não controlado

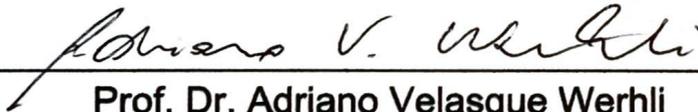
Felipe Bayer Weber

Banca examinadora:



---

Prof. Dr. Roberto Lilles Tavares Machado



---

Prof. Dr. Adriano Velasque Werhli



---

Prof. Dr. Ricardo Nagel Rodrigues



---

Prof. Dr. Paulo Lilles Jorge Drews-Jr  
Orientador(a)

## **AGRADECIMENTOS**

Agradeço a minha família e em especial ao meus pais que me deram todo incentivo, apoio e não mediram esforços para me ajudar durante toda a jornada.

Agradeço a minha noiva Jenifer pelo apoio incondicional e constante incentivo.

Agradeço ao orientador Paulo pela orientação e ensinamentos.

Agradeço ao grupo de pesquisa AutoCERES pelos *insights* e em especial ao Fábio.

*O que quer que a mente  
do homem possa conceber  
e acredite ela pode realizar.*

— NAPOLEON HILL

## RESUMO

WEBER, Felipe Bayer. **Identificação de linhas de plantação em ambiente não controlado**. 2020. 64 f. . Universidade Federal do Rio Grande, Rio Grande.

Ao longo dos últimos anos, a agricultura tem sofrido mudanças profundas devido aos avanços tecnológicos. Dentre esse avanço, a aplicação de agrotóxicos foi uma área que revolucionou a agricultura, diminuindo a mão de obra, aumentando a produtividade e proporcionando um controle maior das plantas espontâneas, insetos e doenças. Mas a maneira de aplicar agrotóxicos se manteve ao longo do tempo, utilizando pulverizadores em barras que aplicam produtos químicos em toda a lavoura. Como normalmente as culturas são plantadas em linhas, otimizar e automatizar a aplicação de defensivos torna-se possível com o uso de novas tecnologias. Para isso desenvolveu-se um sistema baseado no uso de câmera no qual sofre pouca interferência da variação luminosa para segmentar o verde das plantas e a identificação das linhas de plantação. Isso é possível com um algoritmo iterativo que busca maximizar a identificação de linhas baseado em um modelo probabilístico. O algoritmo desenvolvido é flexível ao ponto de identificar diferentes quantidades de linhas de plantação. Ao final, o trabalho apresenta dados estatísticos sobre a eficiência na identificação das linhas do algoritmo proposto.

**Palavras-chave:** Automação, Agrotóxico, Expectation Maximization, Visão Computacional.

## ABSTRACT

WEBER, Felipe Bayer. **Identification of Planting Lines in Areas with Variable Illumination**. 2020. 64 f. . Universidade Federal do Rio Grande, Rio Grande.

Over the past few years, agriculture has undergone profound changes due to technological advances. Among this advance, the application of pesticides was an area that revolutionized agriculture, reducing labor, increasing productivity and providing greater control of spontaneous plants, insects and diseases. But the way to apply pesticides has remained over time, using sprayers in bars that apply chemicals throughout the crop. As crops are normally planted in rows, optimizing and automating the application of pesticides is made possible with the use of new technologies. For this, a system based on the use of a camera was developed in which it suffers little interference from the luminous variation to segment the green of the plants and the identification of the plantation lines. This is possible with an iterative algorithm that seeks to maximize the identification of lines based on a probabilistic model. The developed algorithm is flexible to the point of identifying different amounts of planting lines. At the end, the work presents statistical data on the efficiency in identifying the lines of the proposed algorithm.

**Keywords:** Automation, Agrotoxic, Expectation Maximization, Computer Vision.

## LISTA DE FIGURAS

1	Exemplo de como a identificação de linhas de plantação pode reduzir o desperdício de produtos químicos. Os triângulos em azul representam o leque do bico quando esta aplicando produto, os retângulos em verde quando os bicos estão acionados e o retângulo em vermelho quando o bico esta desligado. . . . .	15
2	Métodos para identificação do verde em imagens RGB. . . . .	18
3	Exemplo de região de interesse e micro-RI [García-Santillán et al., 2017]. . . . .	22
4	Fluxograma de execução do algoritmo. . . . .	26
5	As linhas predominantes iniciam na parte inferior da imagem e se estendem até a parte superior da imagem e estas foram marcadas com linhas azuis. . . . .	27
6	Região de interesse da Figura 5. . . . .	27
7	Resultado final da segmentação do verde da Figura 6. . . . .	28
8	Operação de erosão aplicado sobre a Figura 7. . . . .	28
9	Operação dilatação aplicado sobre a Figura 8. . . . .	29
10	Exemplo de particionamento de dados em cinco conjuntos. . . . .	29
11	Representa o inicial do particionamento e o resultado final depois de ter finalizado a execução do algoritmo. . . . .	31
12	As setas em azul representam o vetor principal que indica a direção das linhas de plantação e a seta em vermelho é o vetor secundário que é sempre perpendicular com o vetor principal. . . . .	32
13	As retas em vermelho representam as linhas de plantação. Os pontos em vermelho são onde as retas se interceptam. . . . .	34
14	Pontos de interseção para dados com três e quatro linhas. . . . .	36
15	Pontos de interseção referentes a Figura 24c. . . . .	37
16	A Figura 16a é a imagem original e a Figura 16b é a RI. . . . .	39
17	A Figura 17a é a imagem original e a Figura 17b é a RI. . . . .	40
18	A Figura 18a é a imagem original e a Figura 18b é a RI. . . . .	41
19	A Figura 19a é a imagem original e a Figura 19b é a RI. . . . .	42
20	Segmentação do verde. . . . .	43
21	Erosão e dilatação. . . . .	43
22	Resultado do particionamento inicial para dados com três, quatro, cinco e seis linhas de plantação. . . . .	43

23	Resultado final da execução do EM para conjunto de dados com três, quatro, cinco e seis linhas de plantação. . . . .	44
24	Resultado final para identificação das linhas com três, quatro, cinco e seis linhas de plantação. . . . .	44
25	As linhas marcadas em azul são as marcações manuais e as linhas em vermelho foram obtidas automaticamente pelo algoritmo. . . .	47
26	Desenho da forma dos polígonos. . . . .	48
27	Área entre as retas manual e automático. . . . .	49
28	Representação geométrica de como é feito o cálculo do ângulo entre dois vetores. . . . .	50
29	Interface do software para classificação dos dados. . . . .	52
30	Resultado da classificação. Cada <i>Nome</i> que repete da imagem é referente à uma linha. A sequência de cima para baixo é a mesma sequência da esquerda para direita para as linhas. . . . .	53
31	Resultado da classificação dividido por quantidade de linhas. . . .	54
32	Porcentagem de acerto do algoritmo por conjunto de dados. . . .	55
33	Porcentagem de acerto do algoritmo. . . . .	55
34	Dados classificados como <i>BOM</i> , <i>REGULAR</i> ou <i>RUIM</i> para o primeiro algoritmo. . . . .	56
35	Dados classificados como <i>BOM</i> , <i>REGULAR</i> ou <i>RUIM</i> para o segundo algoritmo. . . . .	57
36	Dados classificados como <i>BOM</i> , <i>REGULAR</i> são considerados que tiveram sucesso na identificação. . . . .	57
37	Porcentagem de linhas identificadas com sucesso ou erro na identificação das linhas para o método proposto e para os dois métodos que foram comparados. . . . .	58

## LISTA DE TABELAS

1	Tabela de comparação dos métodos de identificação de linhas de plantação. . . . .	23
2	Pontos obtidos automaticamente referentes a Figura 13. . . . .	35
3	Ângulos de inclinação referentes as retas identificadas automatica- mente da Figura 13. . . . .	35
4	Retas e seus respectivos ângulos. As retas iniciam da esquerda para direita. . . . .	37
5	Pontos marcados manualmente e pontos obtidos automaticamente.	46
6	Pontos que formam os polígonos. . . . .	46
7	Pontos que formam os polígonos com suas respectivas áreas. Sem- pre que as retas manual e automática tiver intersecção dentro da RI o polígono é dividido em dois para realizar a cálculo das áreas. Por exemplo: o polígono <sub>1</sub> está dividido em dois, polígono <sub>1,1</sub> e polígono <sub>1,2</sub> . . . . .	48
8	Ângulo e as distâncias entre as retas manual e automático. . . . .	50
9	P1 e P2 são pontos referentes a reta manual e a reta automática e P3 ponto de intersecção e estes pontos são da Figura 25 . . . . .	50
10	Distâncias entre as retas manual e automático. . . . .	51
11	Média e desvio padrão para os dados classificados como <i>BOM</i> e <i>REGULAR</i> . . . . .	54

## LISTA DE ABREVIATURAS E SIGLAS

RGB	<i>Red</i> -Vermelho, <i>Green</i> -Verde, <i>Blue</i> -Azul
ExG	Excesso de verde
ExR	Excesso de vermelho
ExB	Excesso de azul
ExGR	Excesso de verde menos o excesso de vermelho
ExGRB	Excesso de verde menos o excesso de vermelho menos o excesso de azul
CIVE	Índice de cores da extração de vegetação
VEG	Índice de vegetação
COM	Combinação
EM	<i>Expectation Maximization</i>
RI	Região de Interesse

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	13
1.1	Motivação	14
1.2	O problema	15
1.3	Objetivos	15
1.3.1	Objetivos Específicos	15
1.4	Organização do Trabalho	15
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	17
2.1	Métodos de Identificação do Verde em Imagens	17
2.1.1	Excesso de verde	17
2.1.2	Excesso de verde menos o excesso de vermelho	18
2.1.3	Índice de cores da extração de vegetação	19
2.1.4	Índice de vegetação	19
2.1.5	Combinação	20
2.1.6	Excesso de verde menos o excesso de vermelho menos o excesso de azul	20
2.2	Estado da arte para identificação de linhas de plantação	21
<b>3</b>	<b>METODOLOGIA</b>	25
3.1	Visão Geral	25
3.2	Região de Interesse	25
3.3	Segmentação	26
3.3.1	Operações Morfológicas	27
3.4	Definição dos clusters	27
3.4.1	Distribuição de Gaussiana	28
3.4.2	Expectation Maximization	29
3.4.3	Média Aritmética	30
3.4.4	Matriz de covariância	30
3.4.5	Expectativa	31
3.5	Identificação das Linhas	32
3.5.1	Critério de parada do algoritmo	32
3.6	Qualidades das linhas	35
<b>4</b>	<b>RESULTADOS EXPERIMENTAIS</b>	38
4.1	Características dos dados e Região de Interesse	38
4.2	Resultado Quantitativos	39
4.2.1	Resultados de particionamento dos dados	40
4.2.2	Avaliação da Identificação de linhas de plantação	40

<b>4.3</b>	<b>Métricas para mensurar a qualidade dos resultados</b>	45
4.3.1	Área entre as retas manual e automática	45
4.3.2	Ângulo entre dois vetores	47
4.3.3	Distância entre dois pontos	49
<b>4.4</b>	<b>Anotação dos dados para análise quantitativa</b>	51
<b>4.5</b>	<b>Análise quantitativa</b>	51
<b>4.6</b>	<b>Comparação do método proposto</b>	55
<b>5</b>	<b>CONCLUSÃO</b>	59
5.1	Trabalhos futuros	60
	<b>REFERÊNCIAS</b>	61

# 1 INTRODUÇÃO

Todos os setores da economia buscam um aumento da eficiência. Para a agricultura não é diferente. O que segue neste caminho hoje é conhecido como Agricultura de Precisão (AP). Os fundamentos teóricos da AP surgiram em 1929, no Estados Unidos, mas o termo tornou-se conhecido no Brasil na década de 80 [EMBRAPA]. A ideia central está na aplicação da tecnologia no campo para otimizar e aumentar a produtividade da lavoura. As tecnologias mais comuns utilizadas para aumento da produção são: Mecanização, Sistema de Posicionamento Global (GPS) e agroquímicos.

Em conformidade com AP, a chamada revolução verde da década de 50 introduziu novas tecnologias visando a produção de commodities. Após esta revolução, a agricultura vem sendo associada ao uso expressivo de agrotóxicos com o objetivo de controlar e evitar pragas que impactam diretamente em perdas na colheita. Os principais produtos usados são os compostos orgânicos sintéticos onde se encontram os agrotóxicos, principalmente herbicidas, inseticidas e fungicidas. Estes produtos possuem alta atividade biológica podendo causar poluição ambiental e desequilíbrio do agrossistema [Grützmacher et al., 2008]. Em alguns casos, a aplicação efetiva de pesticidas em plantações é de apenas 0,1%, ou seja, 99,9% do produto aplicado tende a se mover para outros locais, por exemplo, águas superficiais e subterrâneas [Ribeiro et al., 2007].

Segundo Resende et al., [2010], as principais regiões agrícolas do país não adotaram extensivamente as técnicas AP, sendo assim, também utilizam um consumo excessivo de agroquímicos. O Brasil em 2011 consumiu em torno de 800 mil toneladas de agroquímicos, sendo 48% foi herbicidas [Ferreira et al., 2012].

Atualmente a aplicação de defensivos é feita por diferentes tipos de pulverizadores, mas a elucidação aqui apresentada é relativa aos pulverizadores em barras sem nenhum tipo de automação dos bicos. Neste tipo de pulverizador os bicos de pulverização são acionados todos de uma única vez. O problema desse tipo de aplicação é que podem ocorrer aplicações de agrotóxico desnecessárias por simplesmente não existir alvo naquela região.

Considerando a necessidade do controle de plantas indesejadas, insetos e doenças

o desperdício que uma aplicação desnecessária de agrotóxicos feita em toda a lavoura causa, uma solução possível e viável é a utilização de novas tecnologias para melhorar a qualidade de aplicação e a redução do desperdício de produtos químicos. Logo, o presente trabalho tem por objetivo a identificação das linhas de cultivo com o uso de visão computacional em ambiente não controlado em campo.

## 1.1 Motivação

A produção de alimentos é dependente do controle de plantas invasoras, doenças e fungos que afetam a qualidade e a produtividade. O controle das mesmas normalmente é feito por pulverizadores em barras que aplicam agrotóxicos em área total sem fazer um controle se há alvo ou não. Para fazer uma aplicação mais consciente é necessário ter um sistema capaz de identificar as linhas de cultivo.

A Figura 1a exemplifica como é feita a aplicação tradicional de defensivos agrícolas, onde todos os bicos são acionados independentemente se na região que está sendo aplicada possui ou não linha de plantação. Na Figura 1b demonstra como é feita a aplicação mais consciente dos produtos quando é feita a identificação das linhas de cultivo.

Existem dois principais tipos de pulverizadores em barras com desligamento de bico. Um é o tipo Uniport 3030 [Jacto] que possui um desligamento de bico a bico. Mas o desligamento do bico é feito com base no GPS. E o outro tipo é o pulverizador Condor 800 AM18 [Jacto] que possui um desligamento por setores inteiros das barras que também utiliza o GPS como base para o desligamento. Mas nem um deles possui um reconhecimento local de linhas de plantação e sim, ambos utilizam um sistema de geolocalização para fazer esse controle.

O *WEEDit* é uma tecnologia desenvolvida pela empresa [Rometron]. O sistema utiliza a técnica de detecção de plantas daninhas por fluorescência de clorofila. Segundo a empresa eles são o único sistema especialista que calibra e corrige muito rapidamente para diferentes condições de aplicação e de solo (seco, úmido e sombra). A desvantagem desse sistema está no alto custo para aquisição e não identifica as linhas de plantação.

Portanto, a principal motivação deste trabalho é devolver um algoritmo baseado em visão computacional que possa identificar as linhas de plantação e esta identificação seja usada para automatizar pulverizador em barras para que apenas os bicos sejam abertos onde possuir linhas de plantação e com isso reduzindo o desperdício de agrotóxicos aplicados para o controle de plantas espontâneas.

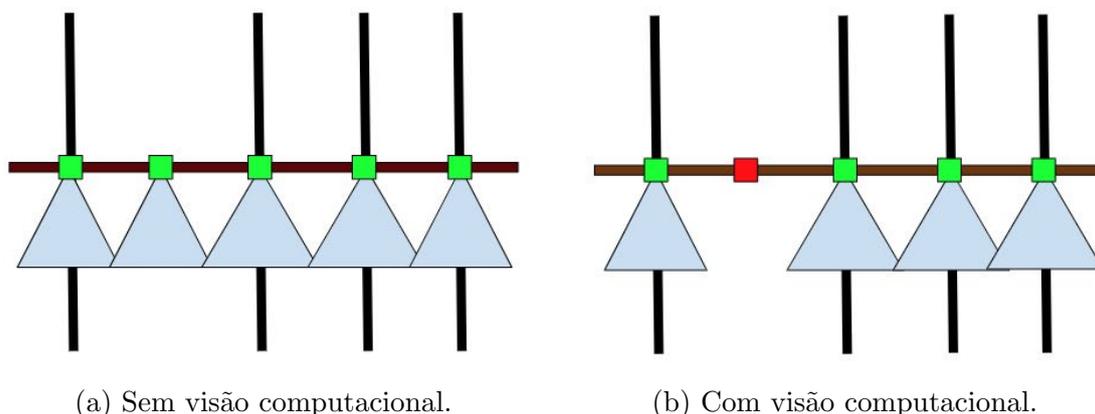


Figura 1: Exemplo de como a identificação de linhas de plantação pode reduzir o desperdício de produtos químicos. Os triângulos em azul representam o leque do bico quando esta aplicando produto, os retângulos em verde quando os bicos estão acionados e o retângulo em vermelho quando o bico esta desligado.

## 1.2 O problema

O presente trabalho tem como problema a identificação de linhas de cultivo com a utilização de imagens coloridas obtidas em ambiente não controlado, ou seja, não se tem o controle sobre a iluminação dos dados durante a obtenção e com diferentes número de linhas nas imagens.

## 1.3 Objetivos

Desenvolver um método de análise de imagem e detecção de linha de cultivo no campo para a cultura de soja.

### 1.3.1 Objetivos Específicos

Os objetivos específicos para este trabalho são:

- Segmentar o verde de forma automática em imagens de plantação.
- Identificar as linhas de cultivo capturadas em ambiente não controlado.
- Avaliar quantitativamente a identificação das linhas.
- Avaliar qualitativamente a identificação das linhas de cultivo para imagens com três até seis linhas de plantação de soja.

## 1.4 Organização do Trabalho

No próximo capítulo será apresentado a revisão bibliográfica onde serão tratados assuntos sobre segmentação do verde e identificação de linhas de plantação. No

Capítulo 3 é apresentado a metodologia para identificação das linhas e métricas para avaliar a qualidade das linhas obtidas. No Capítulo 4 os resultados obtidos com análise estatística com base na classificação dos dados e por fim, as conclusões e trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

A revisão bibliográfica foi dividida em duas partes, a primeira parte é sobre trabalhos que tem o objetivo principal a segmentação do verde agrícola e a segunda parte trabalhos com objetivo principal a identificação das linhas de plantação.

### 2.1 Métodos de Identificação do Verde em Imagens

A segmentação das imagens é um processo de agregação de pixels semelhantes com base na similaridade de suas cores. Um método amplamente utilizado para segmentação de imagens é o limiar. Uma situação ideal é quando o objeto, as plantas, têm um brilho uniforme com o fundo e os demais componentes. Para imagens externas, muitas vezes o brilho do objeto e o do fundo se sobrepõem. Segundo, Tian and Slaughter (1998), essas são situações típicas para imagens capturadas em ambientes externos provenientes de lavouras.

A detecção das linhas de plantação com o uso de visão de máquina tem como objetivo a identificação do verde de plantações agrícolas, o qual, é um tema recorrente em diversos trabalhos [Ribeiro et al., 2005, Granitto et al., 2005, Onyango and Marchant, 2003, Pedersen, 2001, Tian and Slaughter, 1998, Woebbecke et al., 1995, Meyer and Neto, 2008, Kataoka et al., 2003, Hague et al., 2006, Guijarro et al., 2011, Underwood et al., 2015]. Os principais métodos de identificação do verde foram reunidos na Figura 2 e estão classificados pelo tipo de método utilizado para segmentar o que é planta dos demais componentes que podem ter na imagem (solo, pedra, céu, etc).

#### 2.1.1 Excesso de verde

O Excesso de verde (ExG) foi um dos primeiros métodos [Ribeiro et al., 2005, Pedersen, 2001, Woebbecke et al., 1995]. O método *ExG* originalmente foi proposto por Woebbecke et al. (1995) sendo o mesmo utilizado nos trabalhos de Pedersen (2001) e Ribeiro et al. (2005). A segmentação tem por base os três componentes de uma imagem colorida o  $R$ ,  $G$ ,  $B$  (vermelho, verde, azul) que juntos descrevem cada

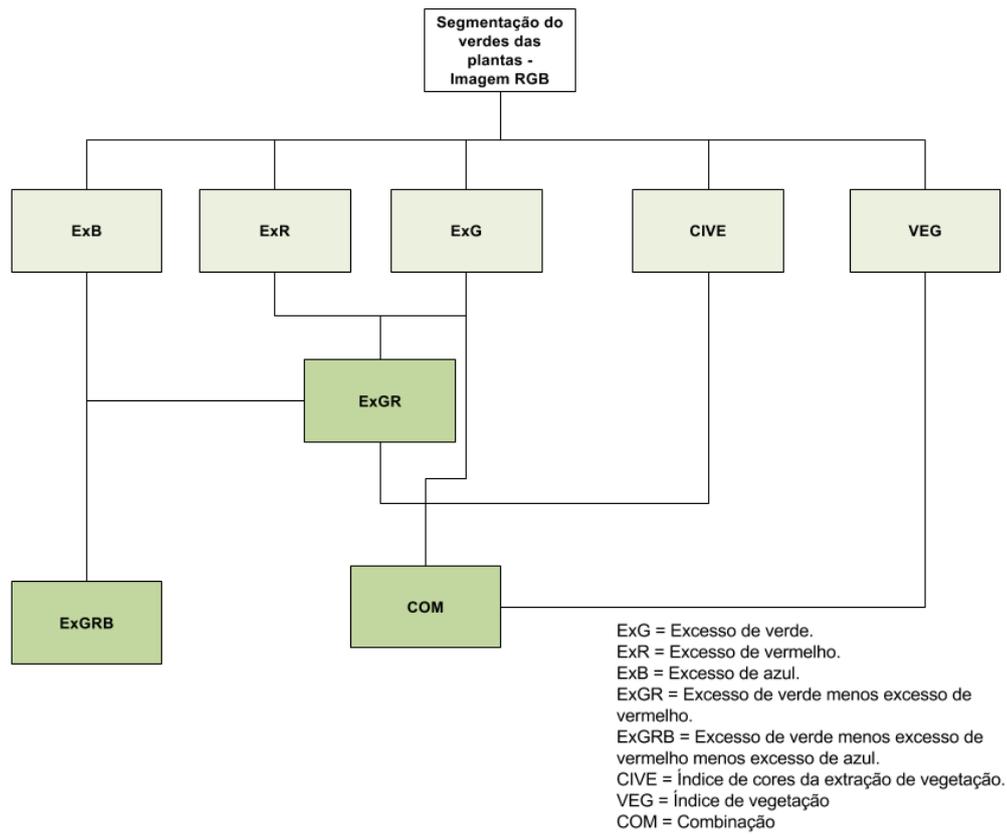


Figura 2: Métodos para identificação do verde em imagens RGB.

pixel da imagem. A primeira etapa da segmentação foi converter a imagem *RGB* em uma imagem monocromática aplicando a Equação 1 pixel por pixel.

$$ExG = rR + gG + bB. \quad (1)$$

De acordo com Woebbecke et al. (1995) os valores que tiveram o melhor desempenho para os coeficientes  $r$ ,  $g$  e  $b$  foram na sequência  $-1$ ,  $2$  e  $-1$ . O próximo passo é determinar o limiar que define o ponto de ruptura entre os pixels que representam a vegetação dos demais pixels que podem ser o solo, pedra, sombras, etc. Na sequência, normaliza-se o valor: se  $ExG \leq 0$  então  $ExG = 0$ ; se  $ExG \geq 255$  então  $ExG = 255$ ; os demais valores dos pixels que ficam entre 0 e 255, junto com os que foram normalizados em 0 ou 255 são os valores que formam a nova imagem. Por fim, a última transformação é a binarização da imagem [Otsu, 1979], onde os pixels com valores 1 representam as plantações e os demais pixels com valor 0 são o solo, pedra, etc.

### 2.1.2 Excesso de verde menos o excesso de vermelho

O segundo método para identificar verdes agrícolas é o excesso de verde menos o excesso de vermelho (ExGR) [Meyer and Neto, 2008]. Segundo Meyer and Neto

(2008) este método supera o algoritmo *ExG* para detecção de vegetação em imagens capturadas com câmeras digitais sob iluminação natural. Para realizar o cálculo deste método primeiro é definido o que é o excesso de vermelho (*ExR*) o qual pode ser visto na equação (2). O valor 1,4 do *ExR* pode ser ajustado dependendo da aplicação e o *R* e *G* são referentes às camadas *RGB*. Portanto, a equação *ExGR* é resultado da subtração das Equações 1 e 2.

$$ExR = 1,4R - G. \quad (2)$$

$$ExGR = ExG - ExR. \quad (3)$$

### 2.1.3 Índice de cores da extração de vegetação

Devido às culturas agrícolas ter a cor verde predominante, o método que foi proposto por Kataoka et al. (2003) para segmentar as plantações do solo, tem o foco na intensidade do RGB. O realce do verde é feito utilizando os valores dos pixels para cada uma das cores para substituir na Equação 4. Com isso o resultado é um novo valor que será o novo pixel. Repetindo a operação para todos os pixels da imagem se obtém um nova imagem de uma camada. E o resultado é uma imagem com o verde mais realçado em relação aos demais componentes da imagem. O nome deste método é *CIVE* (Color Index of Vegetation Extraction) [Kataoka et al., 2003], e *R*, *G*, *B* são os valores das intensidades de cada pixel da imagem colorida. Segundo Kataoka et al. (2003) os valores 0,441, -0,811, 0,385 e 18,78745 são referentes a distribuição de brilho ideal para separação de plantas e solo.

$$CIVE = 0,441R - 0,811G + 0,385B + 18,78745. \quad (4)$$

### 2.1.4 Índice de vegetação

A primeira etapa do processamento digital de imagens agrícolas é identificar os pixels da imagem que representa a parte vegetal. Portanto, o *VEG* foi proposto por Hague et al. (2006) onde imagem é transformada do espaço de cores *RGB* em uma imagem monocromática, avaliando pixel a pixel com a seguinte Equação 5.

$$VEG = \frac{G}{R^a B^{1-a}}. \quad (5)$$

O *VEG* é o índice a ser calculado. O *R*, *G* e *B* são os canais das cores RGB de uma imagem e *a* é uma constante. A imagem monocromática resultante exibe um bom contraste entre a planta e o solo e não é sensível a variação da fonte de iluminação [Hague et al., 2006]. No entanto, esta forma particular também tem a vantagem importante de que existe um valor para o qual o índice também é invariante

para temperatura da cor de um corpo preto [Marchant and Onyango, 2000, Hague et al., 2006]. Esta é uma aproximação para uma ampla gama de luz natural. O valor de  $a$  depende unicamente dos comprimentos de onda centrais dos três filtros de cores da câmera [Marchant and Onyango, 2001, Onyango and Marchant, 2003].

O resultado dessa transformação é que o valor do limiar pode ser usado para separar a vegetação do demais componente, independentemente das mudanças de iluminação [Marchant et al., 2004].

### 2.1.5 Combinação

O quinto método é a combinação de outros métodos já apresentados acima para determinação do verde. Os métodos são:  $ExG$ ,  $ExGR$ ,  $CIVE$  e  $VEG$ . O resultado de cada um é multiplicado por um escalar e a soma resultante é um valor que representa o verde alvo. O resultado deste processo é um limiar de melhor qualidade como demonstra a Equação 6.

$$COM = W_{ExG}ExG + W_{ExGR}ExGR + W_{CIVE}CIVE + W_{VEG}VEG, \quad (6)$$

onde  $W_{ExG}$ ,  $W_{ExGR}$ ,  $W_{CIVE}$ ,  $W_{VEG}$  são pesos para cada índice, representando a importância relativa do índice [Romeo et al., 2013]. Segundo Guijarro et al. (2011) os valores para os quatro pesos são os seguintes:  $W_{ExG} = 0,25$ ,  $W_{ExGR} = 0,30$ ,  $W_{CIVE} = 0,33$ ,  $W_{VEG} = 0,12$ . Estes pesos foram obtidos fazendo a média do verde identificado em cada método.

### 2.1.6 Excesso de verde menos o excesso de vermelho menos o excesso de azul

O último método para segmentação é o excesso de verde menos o excesso de vermelho menos o excesso de azul ( $ExGRB$ ) [Underwood et al., 2015]. Este método utiliza o método anteriormente explicado  $ExGR$  uma vez que supera os outros algoritmos para detecção de vegetação em imagens visuais. Foi subtraído ainda o excesso de azul  $ExB$  para melhorar a detecção. Segundo Underwood et al. 2015 a redução de ruído que a cor azul causava foi descoberto de modo empírico. A equação do  $ExB$  é da seguinte forma:

$$ExB = 1,4B - G. \quad (7)$$

A vegetação é detectada quando o  $ExGR > 0$  [Underwood et al., 2015]. Uma vantagem do método  $ExGR$  é que o limite pode ser fixo em zero, não precisando de ajuste [Meyer and Neto, 2008]. O resultado do  $ExGR$  menos e  $ExB$  é melhor expresso como domínio do verde conforme a Equação 8. O valor do  $k$  da Equação 8

pode ser ajustado para segmentar diversos tipos de verde.

$$G > k(R + B). \quad (8)$$

Existe uma condição canônica para a Equação 9 quando o ruído do pixel prevalece devido à exposição de sombras, sendo assim também pode ser especificado uma intensidade mínima alterando o valor de  $t$  para a classificação.

$$(R + B) > t. \quad (9)$$

Quando ambas as desigualdades nas Equações 8 e 9 são satisfeitas, um pixel é considerado vegetação.

## 2.2 Estado da arte para identificação de linhas de plantação

A identificação de linhas de plantação segundo Rovira-Más et al. (2005), têm por objetivo a automação de máquinas agrícolas onde as linhas são a referência de orientação. O método proposto por Rovira-Más et al. (2005) é definido em cinco etapas: a definição de uma região de interesse, a binarização dos pixels dentro da região, codificação do ponto médio para reduzir uma fileira larga, implementação da transformada de Hough e análise da conectividade para produzir equações das linhas que representam as linha de cultura [Rovira-Más et al., 2005]. Como o objetivo é a automação do trator apenas uma linha precisa necessariamente ser identificada para direcionar o veículo.

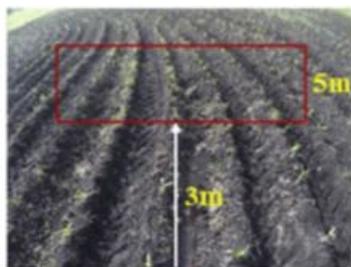
Romeo et al. (2012) propôs um sistema para identificar linhas de culturas em plantação de milho. E para isso, em vez da segmentação do verde foi utilizado um método de limiar simples, em que o limite é previamente estabelecido pela aplicação com uma estratégia de agrupado fuzzy baseada em aprendizado. O próximo passo é a identificação das linhas e como o autor descreve foi inspirado na percepção humana, o que significa, procurar por padrões semelhantes à filas nas imagens.

Montalvo et al. (2012) apresenta um método de identificação de linhas de plantação de cultura de milho com alta concentração de plantas espontâneas. O processo de identificação consiste em três passos principais: a segmentação, o duplo limiar com base no Otsu e a detecção das linhas com regressão linear. Para detecção das linhas utiliza um modelo de referência de onde as linhas deveriam estar, com isso aumenta a precisão mas limita o algoritmo porque precisa o conhecimento prévio de quantas linhas a imagem possui e a distância entre elas.

Guerrero et al. (2013) apresenta um sistema especialista e automático para detecção das linhas de plantação que explora o conhecimento humano e é baseado em dois módulos principais e em técnicas de processamento de imagens. O primeiro

destina-se a segmentação (culturas e plantas espontâneas) do demais componentes. O segundo módulo, a identificação das linhas utilizando a transformada de Hough e, na sequência, a correção das linhas através do estimador Theil-Sen [Thiel, 1950, Sen, 1968]. Segundo o autor essa correção é necessária para evitar desvios significativos nas linhas identificadas causados por ervas daninhas entre linhas ou próximas das mesmas.

García-Santillán et al. (2017) apresenta um método de identificação de linhas de plantação com um diferencial de identificar retas e curvas. O processo inicia com a definição da região de interesse (RI), depois a segmentação das culturas dos demais componentes. Todo processamento é feito definindo RI a qual pode se vista na Figura 3a. Na sequência divide a RI e busca por pontos iniciais que serão os pontos iniciais da reta. Para identificação das linhas, a RI é subdividida em 12 partes, Figura 3b, sendo assim agora se tem 12 micro-RI. Dentro desta micro-RI busca por pixels brancos que representam as plantas. Esse pixel é considerado o segundo ponto para formar a reta. Esse processo se repete até finalizar toda RI identificando todos os pontos que formam a linha de plantação. A Figura 3 exemplifica a identificação dos pontos de interesse.



(a) Região vermelha é a região de interesse.



(b) Micro região de interesse com os pontos que formam a reta.

Figura 3: Exemplo de região de interesse e micro-RI [García-Santillán et al., 2017].

Em Winterhalter et al. (2018) apresenta um sistema para a identificação das linhas de plantação em qualquer estágio de crescimento. O algoritmo é capaz de estimar o ângulo, o deslocamento lateral e o espaçamento entre linhas e é particularmente adequado para plantas pequenas. Para conseguir detectar tanto plantas pequenas como plantas grandes foi utilizado dois sensores para aquisição dos dados. Uma câmera RGB e um *scanner* a laser. E a combinação da extração das características dos dados de cada sensor foi utilizado para identificar as linhas de plantação. As linhas de plantação foram identificadas por quatro algoritmos diferentes: o *Hough Line*, o *Dual Hough Line*, uma variação do *Hough* o *Pattern Hough* e uma variação do *RANSAC* o *Pattern RANSAC*. Segundo os autores o *Pattern RANSAC* teve

um melhor desempenho na identificação das linhas quando as plantas era muito pequenas.

No trabalho de Zhang et al. (2018) apresenta a detecção automática de linhas de plantação com base no algoritmo de agrupamento de posições e no método de caminho mais curto. O método proposto foi dividido em três partes: a segmentação da imagem, extração de pontos característicos e a detecção das linhas de colheita. A segmentação da imagem é baseada na aplicação de um índice de vegetação modificado e duplo limiar, combinando o método *Otsu* com a otimização da nuvem de partículas, conseguindo assim uma separação entre as ervas daninhas e as culturas. Durante o procedimento de detecção de linha de plantação, o algoritmo de agrupamento de posição e o método de caminho mais curto foram aplicados sucessivamente para confirmar o conjunto final de pontos característicos que foram agrupados. Finalmente, o método de regressão linear baseado em mínimos quadrados foi empregado para ajustar as linhas da colheita.

A Tabela 1 abaixo reúne os métodos de identificação de linhas em plantação apresentados anteriormente e foram classificados quanto as principais características. Para classificação foi levado em conta se os trabalhos resolvem ou se não resolvem o problema.

A seguir é apresentado o que cada uma das características significa:

- Limiar automático: sem ajuste adicional para segmentar o verde das imagens.
- Linhas automáticas: identifica o número de linhas sem a necessidade de informação extra de quantas linhas tem na imagem.
- Variabilidade luminosa: eficiência em segmentar o verde das imagens em diferentes condições de iluminação.
- Diferentes tamanhos: flexibilidade para identificar linhas de plantação independente do tamanho da cultura.
- Localização das linhas: se o método utiliza referência de onde as linhas estão.

Métodos	Limiar Automático	Linhas Automáticas	Flexibilidade Luminosa	Diferentes Tamanhos	Localização das Linhas
[Rovira-Más et al., 2005]	Não	Sim	Sim	Não	Sim
[Romeo et al., 2012]	Não	Não	Sim	Sim	Sim
[Montalvo et al., 2012]	Não	Não	Sim	Sim	Sim
[Guerrero et al., 2013]	Não	Não	Não	Não	Sim
[García-Santillán et al., 2017]	Sim	Não	Sim	Sim	Não
[Zhang et al., 2018]	Sim	Sim	Não	Sim	Não
[Winterhalter et al., 2018]	Não	Não	Sim	Não	Sim
Proposto	Sim	Não	Sim	Sim	Não

Tabela 1: Tabela de comparação dos método de identificação de linhas de plantação.

As principais características almeçadas foram reunidas na Tabela 1. Nem um dos trabalhos resolve o problema como um todo mas todos lidam parcialmente. Todas as

características desejadas estão assinaladas com um **Sim** na tabela menos a última coluna que a característica desejadas é a que possui **Não**.

## 3 METODOLOGIA

Nesta seção será apresentado o método proposto para identificação de linha de cultura do soja. A Seção 3.1 é a visão geral do fluxo de execução do algoritmo. Na Seção 3.2 é apresentado o que é e como é obtido a região de interesse (RI). Na Seção 3.3 é onde é feita a segmentação das plantas dos demais componentes. Na Seção 3.4 é a parte da definição dos clusters, qual técnica utilizada e porquê definir os dados em conjuntos é importante, e como é feito para reorganizar os dados dos conjuntos encontrando a máxima verossimilhança entre os mesmos. Na Seção 3.5 como é feito a identificação das linha de cultura e na ultima seção como foi feito a avaliação da qualidade das linhas identificadas.

### 3.1 Visão Geral

A Figura 4 ilustra de forma geral a metodologia. A entrada de dados é uma imagem colorida, a Parte 1, é a definição da região de interesse (RI). Na Parte 2, é a segmentação onde o verde é identificado. Na Parte 3, onde é feita as operações morfológicas. Na Parte 4, é feita a divisão dos dados em grupos. Na Parte 5, onde é feita a identificação das linhas de plantação. Por fim, a saída do algoritmo são as linhas identificadas.

### 3.2 Região de Interesse

A Parte 1 do processamento é definir a região de interesse (RI). A RI consiste em uma área da imagem onde as linhas de plantação existem em toda a imagem. Isso significa que as linhas iniciam muito próximo da parte inferior da imagem até a parte superior da imagem. A Figura 5 exemplifica o que é uma linha de plantação predominante.

Sabendo que a RI precisa ter apenas as principais linhas de plantação, para esse conjunto de dados, a RI é composta por 40% da imagem partindo da parte inferior. Esse valor para o RI foi obtido com testes observacionais. A Figura 6 é a RI da Figura 5.

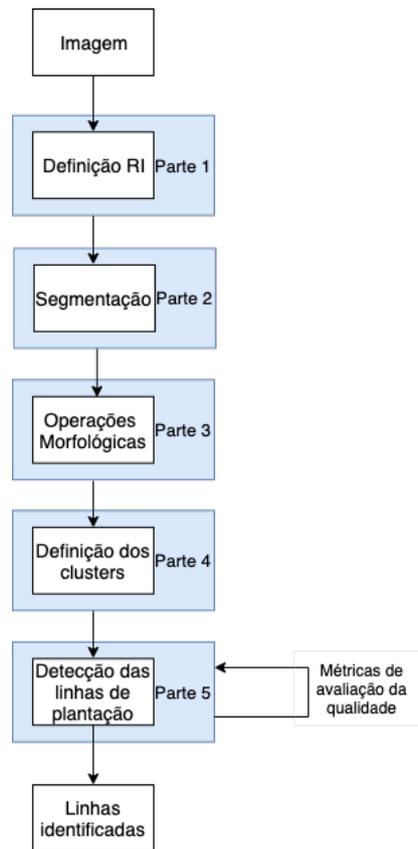


Figura 4: Fluxograma de execução do algoritmo.

Uma característica que pode ser observado nas Figuras 5 e 6 é que as linhas de cultivo não são paralelas na imagem mas no mundo elas podem ser consideradas como sendo paralelas. Esse é um efeito de perspectiva que se deve a forma como os dados foram adquiridos com um ângulo de inclinação aproximadamente de  $35^\circ$  em relação ao solo.

### 3.3 Segmentação

A segmentação neste trabalho é um processo que busca separar o que é planta dos demais componentes. E para isso o método utilizado foi o *ExGRB* por ser possível ajustar a intensidade de cores através das Equações 8 e 9. O valor de  $k$  da equação 8 e o valor de  $t$  da equação 9 podem ser ajustados para seja possível a segmentação de diferentes tonalidades de verde. Isso é uma característica importante já que os dados são capturados em ambiente de luminosidade não controlada e diferentes estágios de crescimento da plantação, o que pode ter variação nos tons de verde.

O processo de segmentação percorre pixel a pixel verificando se o valor do pixel é congruente com os valores de pixels buscados. Identificando esses pixels os mesmos são alterado para a cor branca. O resultado da segmentação pode ser visto na Figura 7.



Figura 5: As linhas predominantes iniciam na parte inferior da imagem e se estendem até a parte superior da imagem e estas foram marcadas com linhas azuis.



Figura 6: Região de interesse da Figura 5.

### 3.3.1 Operações Morfológicas

As operações morfológicas foram usadas com intuito de reduzir o ruído nos dados. Primeiro foi utilizado a erosão para remover alguns elementos que foram identificados mas que não fazem parte das linhas de plantação. Após a erosão foi utilizado a dilatação para realçar os dados e em alguns casos unem-se os objetos próximos. O tamanho do *kernel* utilizado para erosão foi de  $3 \times 3$  e o *kernel* utilizado para dilatação foi  $5 \times 5$ . O resultado da operação erosão pode ser visto na Figura 8 e o resultado da operação dilatação pode ser visto na Figura 9.

## 3.4 Definição dos clusters

O conjunto de dados resultante da operação erosão neste momento não representa as linhas de plantação. São apenas dados que precisam ser classificados. Para isso é importante poder quantificar a probabilidade de um determinado dado pertencer a um ou mais cluster, isso permite descrever com mais precisão os dados. Foi utilizada a técnica de *soft clustering* para descrever os dados.

A divisão dos dados em grupos tem como base o número de linhas de plantação e esse é um conhecimento prévio. Os dados foram divididos conforme a seguinte



Figura 7: Resultado final da segmentação do verde da Figura 6.



Figura 8: Operação de erosão aplicado sobre a Figura 7.

Equação 10, onde  $n$  é o número de linhas,  $w$  é a largura da imagem em pixel e  $Cs$  é a largura que cada conjunto vai ter.

Por exemplo para 3 linhas a divisão de cada cluster fica assim: Primeiro cluster começa em zero no eixo  $x$  e vai até  $Cs$ , o segundo cluster começa onde termina o primeiro mais  $Cs$  e o terceiro cluster começa onde termina o segundo e vai até a largura da imagem. Esse processo é semelhante para as imagem com 4, 5 e 6 linhas. A Figura 10 é um exemplo de particionamento dos dados.

$$Cs = w/n \quad (10)$$

### 3.4.1 Distribuição de Gaussiana

Uma das mais importantes distribuições de probabilidade para variáveis contínuas, é a distribuição Normal ou Gaussiana. Sua importância se deve principalmente ao teorema central do limite, pois ele garante mesmo que os dados não sejam distribuídos segundo a normal, a média dos dados converge para uma distribuição normal conforme o número de dados aumenta.

Para uma variável de valor  $x$ , a distribuição Gaussiana é definida pela Equação 11 e os dois parâmetros adicionais são: média ( $\mu$ ) e o desvio padrão ( $\sigma^2$ ).

$$N(x|\mu,\sigma^2) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left\{-\frac{1}{2\sigma^2}(x-\mu)^2\right\}. \quad (11)$$

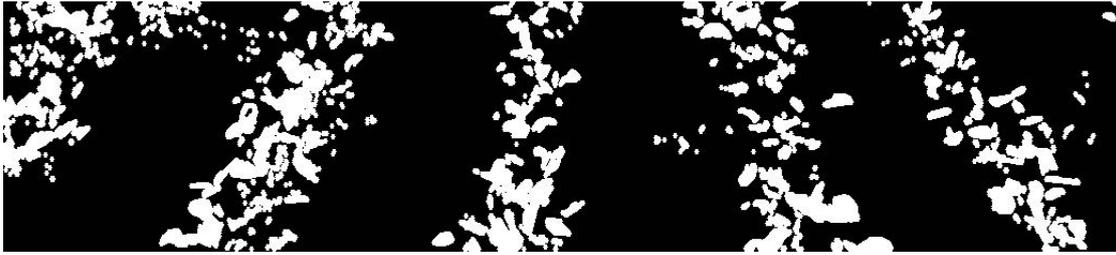


Figura 9: Operação dilatação aplicado sobre a Figura 8.

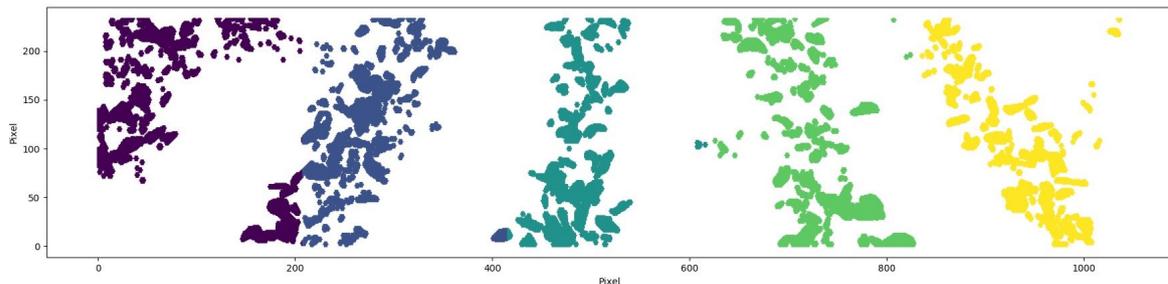


Figura 10: Exemplo de particionamento de dados em cinco conjuntos.

### 3.4.2 Expectation Maximization

Um método elegante e poderoso para encontrar soluções de máxima verossimilhança de parâmetros em modelos probabilísticos com variáveis latentes é chamado de algoritmo Expectation Maximization (EM) ou Maximização da Expectativa [Bishop, 2006]. EM é um método iterativo que alterna entre dois passos, expectativa (E) e de maximização (M). Para clusterização, o EM utiliza do modelo finito de misturas Gaussianas e estima um conjunto de parâmetros de forma iterativa até que um valor de convergência seja alcançado. A mistura é definida como um conjunto de distribuições de probabilidades e cada distribuição corresponde a um cluster. Uma instância (valor) é atribuída com uma probabilidade de associação para cada ponto de dados e esses pontos são atribuídos a cada cluster.

Funcionamento do EM para clusterização:

1. Calcula para cada componente os parâmetros iniciais: média ( $\mu$ ) e matriz de covariância ( $\Sigma$ ).
2. Calcula iterativamente os passos *E* e *M*:
  - Passo E: calcula a probabilidade de associação para cada instância com base nos parâmetros média e matriz de covariância.
  - Passo M: Recalcula os parâmetros com base nas novas possibilidades de associação.
3. Atribua cada instância ao cluster com o qual possui a maior probabilidade de associação.

Quando o passo M for executado pela primeira vez ele calcula os parâmetros como a média e matriz de covariância utilizando os clusters particionados inicialmente como as informações iniciais. Após a primeira execução os dados foram reorganizados segundo o cálculo da probabilidade a priori do passo E, e esses que serão utilizados durante o novo passo M.

### 3.4.3 Média Aritmética

Em estatística a media aritmética é muito utilizada como uma medida de tendência central. Para isso, é obtida fazendo a soma de todos os elementos e dividindo pelo número total dos mesmos. A Equação 12 determina como é feita o cálculo da média. Esse cálculo é feito para cada um dos clusters. O  $n$  é o número de elementos e o  $\gamma_i$  é definido como  $1D$ .

$$\mu = \frac{1}{n} \sum_{i=1}^n \gamma_i. \quad (12)$$

### 3.4.4 Matriz de covariância

O próximo parâmetro a ser calculado é a matriz de covariância ( $\Sigma$ ). A matriz para dados  $2D$  é composta com a variância de  $\sigma_{(x,x)}$ ,  $\sigma_{(y,y)}$ ,  $\sigma_{(x,y)}$  e  $\sigma_{(y,x)}$ . Sendo que a variância de uma variável aleatória é uma medida da sua dispersão estatística, indicando a distância de forma geral para onde os valores se encontram do valor esperado. E esses quatros valores estão reunidos na matriz de covariância.

Se  $x$  possui relação direta com  $y$ ,  $y$  também se relaciona diretamente com  $x$ . Em outras palavras, podemos afirmar que  $xy = yx$  estão diretamente ligados. Portanto, a matriz de covariância é sempre uma matriz simétrica com as variâncias em sua diagonal principal e as covariâncias na diagonal secundária.

$$\sigma_{x_e}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2 = \sigma_{(x_e, x_e)}, \quad (13a)$$

$$\sigma_{x_e, y_e}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu x)(y_i - \mu y), \quad (13b)$$

$$\Sigma = \begin{bmatrix} \sigma_{(x_e, x_e)} & \sigma_{(x_e, y_e)} \\ \sigma_{(y_e, x_e)} & \sigma_{(y_e, y_e)} \end{bmatrix}. \quad (13c)$$

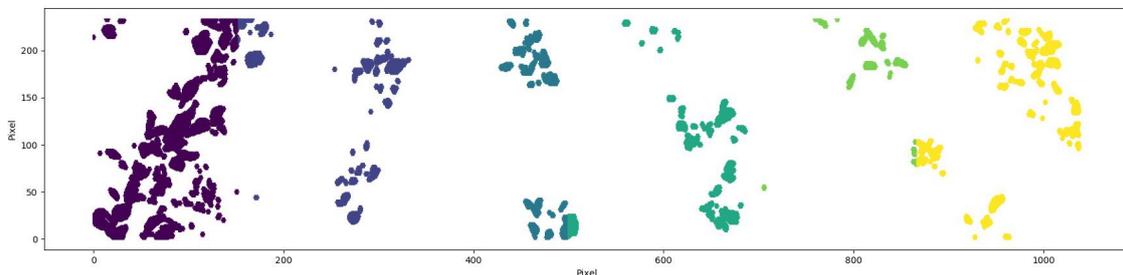
Nas Equações 13a, 13b e 13c o  $x_e$  e  $y_e$  que são parâmetros que se referem aos eixos coordenados  $x$  e  $y$  foi alterado para melhor compreensão.

### 3.4.5 Expectativa

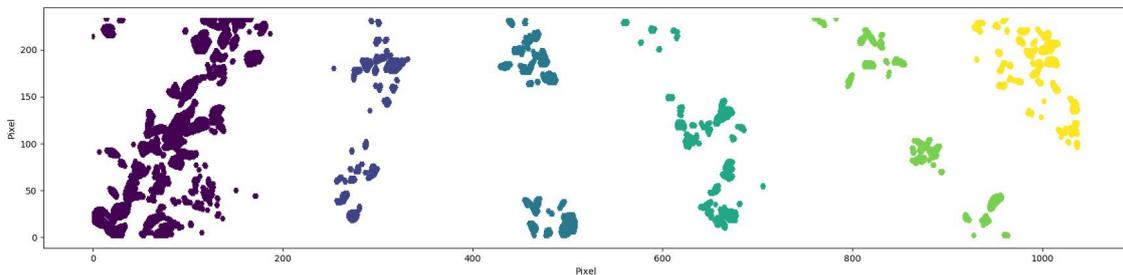
O passo  $E$  calcula a probabilidade de cada ponto de dados pertencer a um determinado clusters. Sendo assim cada ponto de dados vai receber uma probabilidade de pertencimento a um conjunto. Tem um conjunto de dados que precisam ser agrupados em várias partes ou clusters com base em sua similaridade. E para isso foi utilizado o método de clusterização do modelo de mistura gaussiana ( $GMM$ ). Para uma distribuição multivariada é natural que um conjunto de dados vêm de diferentes Gaussianas. Para o trabalho em questão, cada uma das linhas de plantação é considerada um conjunto de dados que segue a distribuição normal e todos os clusters são considerados uma  $GMM$ . A função de densidade normal multivariada é definida segundo a Equação 14 onde  $\mu$  é a média,  $\Sigma$  a matriz de covariancia,  $D$  é a dimensão do espaço e  $x$  são as coordenadas do pixels.

$$N(x|\mu,\Sigma) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right\}. \quad (14)$$

Após o cálculo da probabilidade é realizado a comparação das probabilidades resultantes dos pixels para saber a qual cluster existe maior probabilidade de pertencer. A Figura 11b exemplifica a alteração de clusters.



(a) Definição inicial.



(b) Resultado final.

Figura 11: Representa o inicial do particionamento e o resultado final depois de ter finalizado a execução do algoritmo.

A iteração do passo  $E$  pára quando as métricas de avaliação da qualidade das linhas de plantação forem satisfeitas, que são o Ponto de fuga e o Ângulo de Inclinação (essa duas medidas vão ser explicadas mais tarde) ou quando a variação dos dados for menor que 0,07. Quando essa variação for muito pequena significa que a movimentação

de dados de um cluster para o outro é muito pequena e não gera mais impacto no resultado e também significa que o EM convergiu para um valor ideal, porem nem sempre o valor ideal é a Gaussiana buscada.

### 3.5 Identificação das Linhas

Para identificar as linhas de plantação utiliza-se o conceito de matriz de covariância que representa uma medida de dispersão bidimensional de duas variáveis aleatórias  $x$  e  $y$  no plano cartesiano.

Se a matriz de covariância define a dispersão dos dados e sua orientação, através de uma transformação linear. Conforme a Equação 15, é possível encontrar o autovetor e o autovalor principal e secundário da matriz.

$$\Sigma v = \lambda v. \quad (15)$$

O resultado da identificação pode ser visto na Figura 12, onde a origem do autovetor é a média da distribuição da Gaussiana e o ponto final do vetor é definido pelo autovetor. A magnitude do autovetor é definido pela raiz quadrada do autovalor.

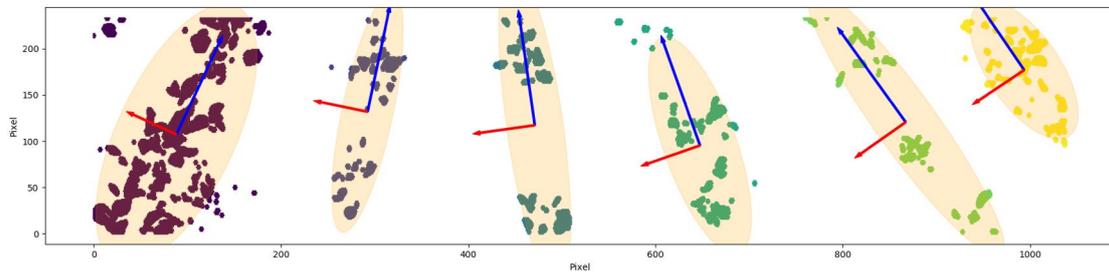


Figura 12: As setas em azul representam o vetor principal que indica a direção das linhas de plantação e a seta em vermelho é o vetor secundário que é sempre perpendicular com o vetor principal.

#### 3.5.1 Critério de parada do algoritmo

Para verificar a qualidade das linhas identificadas é muito importante saber quando finalizar o algoritmo e, se as linhas que foram obtidas, são consideradas linhas de plantação. Para isso, as métricas utilizadas para avaliar as linha obtidas foram: Ponto de Fuga e Ângulo de Inclinação. E estas são as condições que validam as linhas identificadas como tendo as características necessárias para ser considerado como linhas de plantação.

##### 3.5.1.1 Ponto de Fuga

O conceito de ponto de fuga é usado para determinar um lugar geométrico onde as projeções das retas conflui em certos pontos. Mas para isso as retas não podem ser

paralelas e precisam pertencer ao mesmo plano. O que possibilita a utilização deste conceito é porque as imagens foram capturadas em perspectiva em relação ao solo, o que resulta linhas que possuem interseção em algum ponto no mesmo plano. Para obter o ponto de encontro das retas primeiro é preciso saber quais pontos formam a mesma. O primeiro ponto da reta é o centróide do cluster e o segundo ponto é um múltiplo do autovetor principal. A equação 16 demonstra como é feito o cálculo, onde  $(cx,cy)$  é o centroide, e o  $(ava)$  autovalor da variação de dados em  $y$  e o autovetor em relação a  $y$  é  $(ave_x,ave_y)$ .

$$\begin{aligned} pt1 &= (cx,xy), \\ pt2 &= (cx + (ave_x * ava), cy + (ave_y * ava)). \end{aligned} \tag{16}$$

Com dois pontos é possível encontrar a equação da reta utilizando o conceito de três pontos colineares. Para isso basta obter o determinante conforme a Equação 17. Onde,  $(x_1,y_1)$  e  $(x_2,y_2)$  são os pontos que foram obtidos usando a Equação 16 e estes dois pontos formam a reta.

$$det = \begin{bmatrix} x & y & 1 \\ x_1 & y_1 & 1 \\ x_2 & y_2 & 1 \end{bmatrix} = 0. \tag{17}$$

O resultado do determinante é a equação geral da reta. Basta repetir o processo anterior para encontrar a outra equação geral da reta. Para encontrar o ponto de intersecção das retas concorrentes, basta encontrar a equação reduzida de ambas as retas e após isso igualá-las. O resultado dessa igualdade é o ponto de intersecção. O resultado pode ser vista na Figura 13.

Nem todo ponto de fuga necessariamente é o encontro de duas linhas de plantação válidas. E para resolver esse problema o ponto de encontro das duas retas tem que ter a coordenada positiva em  $y$ . Isso se deve pela forma como os dados foram capturados com um ângulo de inclinação em relação ao solo, uma consequência disso que o encontro das retas sempre vai estar na parte superior da imagem.

### 3.5.1.2 Ângulo de inclinação

Conhecendo os pontos que formam uma reta é possível saber o ângulo de inclinação que a mesma tem em relação ao eixo de coordenadas. Essa inclinação é importante para verificar se as linhas identificadas podem ser consideradas como as linhas de plantação. Para isso, o ângulo de inclinação tem que estar entre  $50^\circ$  e  $140^\circ$ . O cálculo do ângulo foi feito utilizando a seguinte Equação 18.

$$a = \tan^{-1} \left( \frac{\Delta y}{\Delta x} \right). \tag{18}$$

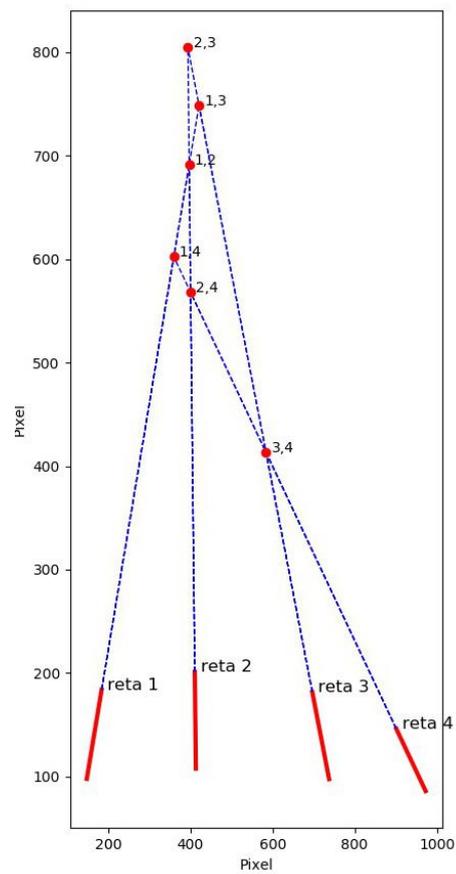


Figura 13: As retas em vermelho representam as linhas de plantação. Os pontos em vermelho são onde as retas se interceptam.

	Pontos	
Reta 1	$x_1 = 106$	$y_1 = 0$
	$x_2 = 204$	$y_2 = 234$
Reta 2	$x_1 = 415$	$y_1 = 0$
	$x_2 = 409$	$y_2 = 234$
Reta 3	$x_1 = 786$	$y_1 = 0$
	$x_2 = 670$	$y_2 = 234$
Reta 4	$x_1 = 1032$	$y_1 = 0$
	$x_2 = 876$	$y_2 = 234$

Tabela 2: Pontos obtidos automaticamente referentes a Figura 13.

Na Tabela 2 reúne os pontos que foram obtidos através do algoritmo e esses pontos são referentes a Figura 13. Lembrando que as retas em vermelho são as retas obtidas automaticamente e exemplificam as linhas de cultivo identificadas. O resultado do ângulo de inclinação pode ser visto na Tabela 3.

Retas	Ângulos em graus
1	67,2
2	91,5
3	116,4
4	123,7

Tabela 3: Ângulos de inclinação referentes as retas identificadas automaticamente da Figura 13.

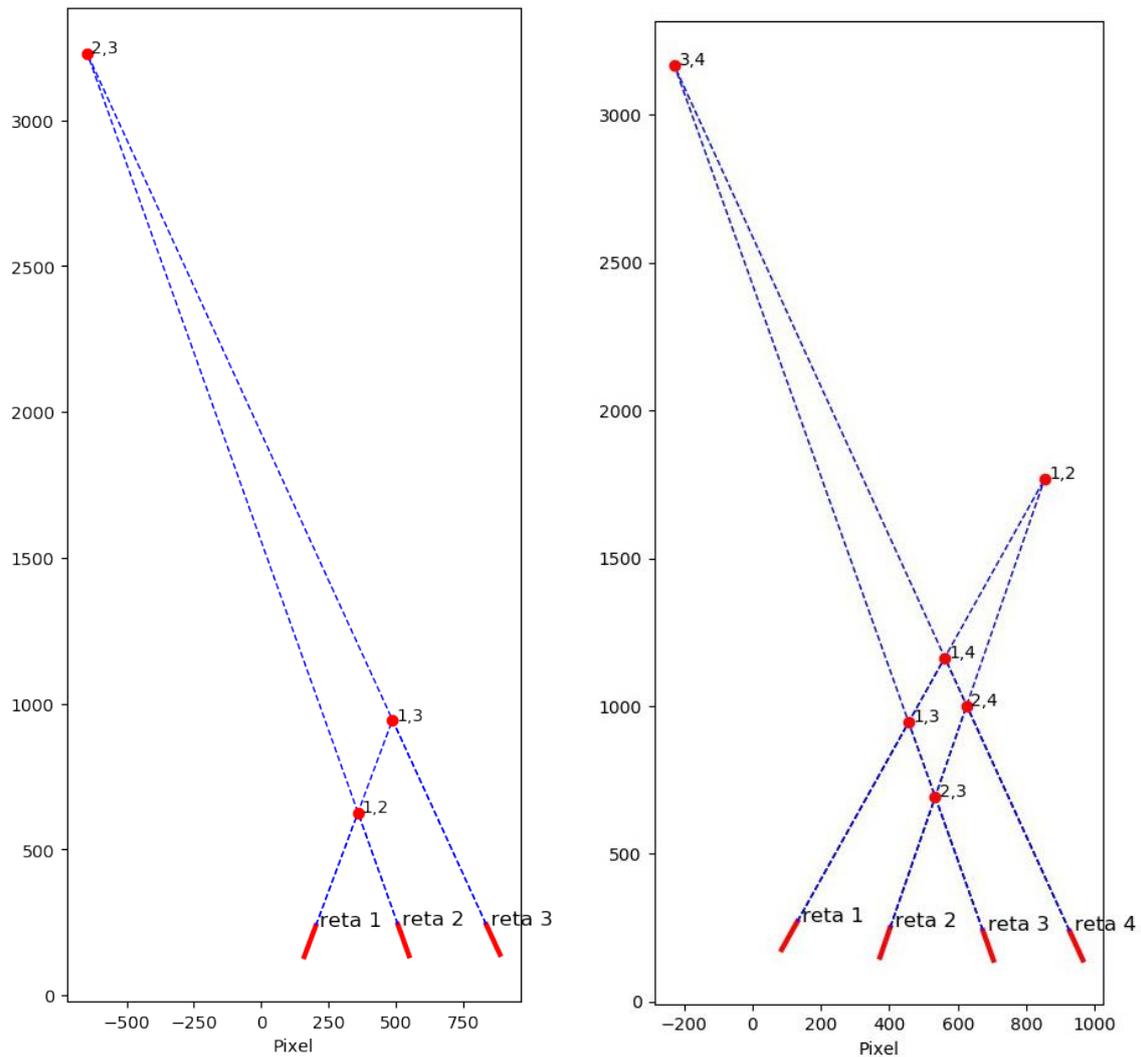
Essas duas métricas, ponto de fuga e ângulo de inclinação são verdadeiras assumindo que o ângulo da câmera relação ao solo que fique entre 20 e 70 graus. Essa restrição é importante para que se tenha linhas convergentes. Quanto mais próximo de zero ou de noventa graus a tendência que as linhas de cultura se aproximem de serem linhas paralelas.

### 3.5.1.3 Parada do algoritmo

Determinar quando o algoritmo pára a execução é muito importante para melhorar a eficiência na obtenção dos resultados e para isso o critério de parada se torna um ponto importante. Portanto, quando o ponto de fuga e o ângulo de inclinação forem satisfeitos a execução é finalizada.

## 3.6 Qualidades das linhas

As métricas de avaliação da qualidade das linhas de plantação identificadas são uma boa referência para finalizar a execução do algoritmo e avaliar se as linhas identificadas correspondem com a realidade. A condição para o Ponto de Fuga para a



(a) Pontos de intersecção referentes a Figura 24a (b) Pontos de intersecção referentes a Figura 24b

Figura 14: Pontos de intersecção para dados com três e quatro linhas.

coordenada  $y$  ser positiva é válida porque os dados capturados estão em perspectiva e sempre neste contexto o  $y$  vai ser maior que zero.

A outra medida de qualidade das linhas identificadas é o ângulo de inclinação em relação ao eixo de coordenadas. Toda linha que representa uma linha de plantação tem um ângulo que varia de  $50^\circ$  até  $140^\circ$ . A Tabela 4 reúne os ângulos de inclinação para as Figuras 24a, 24b, 24c e 24d.

A Figura 14 representa os pontos de fuga para as Figuras 16b e 17b e a Figura 15 é demonstra como são os pontos de intersecção da Figura 24c. Para dados com mais de cinco linhas de plantação não é possível gerar resultados visuais claro, ou seja, sempre vai existir pontos de intersecção muito próximos e a quantidade de intersecções deixa o dado visual poluído e de difícil entendimento.

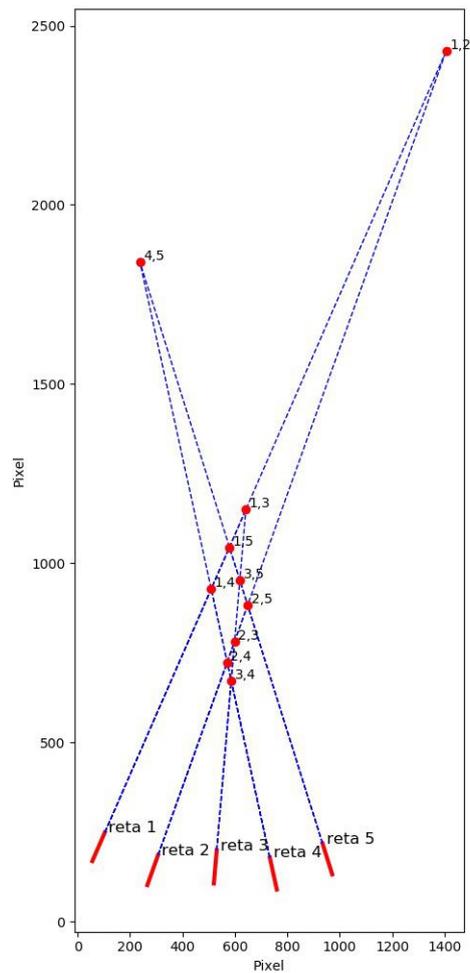


Figura 15: Pontos de interseção referentes a Figura 24c.

Figura 24a		Figura 24b	
Retas	Ângulos em graus	Reta	Ângulos em graus
1	67,9	1	64,4
2	111,2	2	73,4
3	116,5	3	106,7
		4	111,4

Figura 24c		Figura 24d	
Retas	Ângulos em graus	Retas	Ângulos em graus
1	59,3	1	59,3
2	64,1	2	68,2
3	83,2	3	94,2
4	106,7	4	112,8
5	113,4	5	126,3
		6	131,1

Tabela 4: Retas e seus respectivos ângulos. As retas iniciam da esquerda para direita.

## 4 RESULTADOS EXPERIMENTAIS

O objetivo deste capítulo é avaliar a metodologia desenvolvida para a identificação das linhas de plantação. Na Seção 4.1 é apresentado as características dos dados e cultura utilizada. Na Seção 4.2 é feita uma avaliação do método de identificação do verde das plantações. Na Seção 4.3 apresenta os resultados obtidos para particionamentos dos dados. Na Seção 4.4 é feita uma avaliação da identificação das linhas de plantação. A Seção 4.5 apresenta os resultados qualitativos para a identificação das linhas de plantação para imagens com três, quatro, cinco e seis linhas. Por fim, na Seção 4.6 é apresentado os resultados quantitativos da identificação.

### 4.1 Características dos dados e Região de Interesse

O estudo apresentado foi realizado em uma plantação de soja na região central do estado do Rio Grande do Sul na cidade de Toropi. A soja é uma das principais culturas cultivadas no país e de suma importância para a economia do Brasil. O *dataset* é composto por 140 imagens que foram obtidas em dois momentos no intervalo de uma semana, sendo que a primeira parte foi no período da manhã e a segunda parte foi no período da tarde. Nesses dois períodos a condição de iluminação era de céu limpo e ensolarado. A divisão dos dados por quantidade de linhas ficou assim: São 20 com 3 linhas, 27 com 4 linhas, 50 com 5 linhas e 43 com 6 linhas. O aparelho utilizado para aquisição das imagens foi um Motorola XT1097 com uma câmera de 13Mpx e com distância focal f2,25.

Os dados foram capturados sob projeção de perspectiva no sentido longitudinal da plantação. Para o melhor funcionamento do algoritmo é importante que a RI contenha apenas as principais linhas de plantação da imagem, que são as linhas predominantes que iniciam no inferior da imagem e vão até o extremo superior da imagem. As Figuras 16, 17, 18 e 19 são imagens coletadas e com suas regiões de interesse para imagens com três, quatro, cinco e seis linhas de plantação.



(a)



(b)

Figura 16: A Figura 16a é a imagem original e a Figura 16b é a RI.

## 4.2 Resultado Quantitativos

Para a segmentação do verde foi utilizado as Equações 8 e 9 que são dependente dos parâmetros  $k$  e  $t$ . Esses parâmetros podem ser ajustados para limitar o verde a ser identificado. O valor padrão que foi utilizado foi  $k = 0,35$  e  $t = 30$ , onde esses valores foram os que tiveram um melhor desempenho segmentando o verde de diferentes intensidade. As Figuras 20a, 20b, 20c e 20d são o resultado da segmentação para algumas imagens.

Após a segmentação, todas as imagens passam pelo processo de erosão e dilatação. A Figura 21 reúne a erosão e a dilatação referentes a Figura 20.



(a)



(b)

Figura 17: A Figura 17a é a imagem original e a Figura 17b é a RI.

#### 4.2.1 Resultados de particionamento dos dados

Nesta seção é apresentado o resultado do particionamento dos dados referentes a identificação do verde. Essa divisão sempre tem como base o número de linhas de plantação e a largura da imagem em pixels. O número de linhas é um conhecimento prévio e a largura em pixels é definida com sendo de 1040 pixels ou seja, toda a imagem. A Figura 22 é o resultado da clusterização do dados, onde cada cor representa um cluster. O que pode ser observado na Figura 22 que o particionamento inicial cria clusters que visualmente não são exatamente as linhas de colheita, mas que são uma boa sugestão inicial para o EM.

#### 4.2.2 Avaliação da Identificação de linhas de plantação

O EM é um algoritmo que utiliza a máxima verossimilhança para encontrar soluções. Para o caso específico o particionamento dos dados, mostrou-se eficiente em



(a)



(b)

Figura 18: A Figura 18a é a imagem original e a Figura 18b é a RI.



(a)



(b)

Figura 19: A Figura 19a é a imagem original e a Figura 19b é a RI.

direcionar a conversão dos dados que possuem maior probabilidade de pertencimento a um mesmo cluster. Sendo assim os dados que estão mais ao centro do conjunto de dados tem a maior probabilidade de pertencer. O resultado dessa probabilidade pode ser visto na Figura 23 onde a elipse em torno dos dados representa dois desvio padrão ou 97,1% dos dados.

A matriz de covariância representa a variabilidade dos dados. Sendo assim, é possível utilizar a matriz de covariância e obter os autovetores e autovalores. Os autovetores são a direção para os onde os dados variam e os autovalores a dimensão ou o tamanho dos autovetor. Como pode ser visto na Figura 23 é possível obter com grande precisão as linhas de plantação através dos autovetores.

Utilizando os autovetores obtidos através na matriz de covariância foi possível identificar as linhas de plantação. A Figura 24 demonstra como ficou a identificação das linhas. Na Figura 24a fica mais evidente a perspectiva das linhas de cultivo. A linha em azul representa a linha de plantação identificada. A perspectiva se deve pela forma como os dados foram capturados com um ângulo de inclinação em relação ao solo.

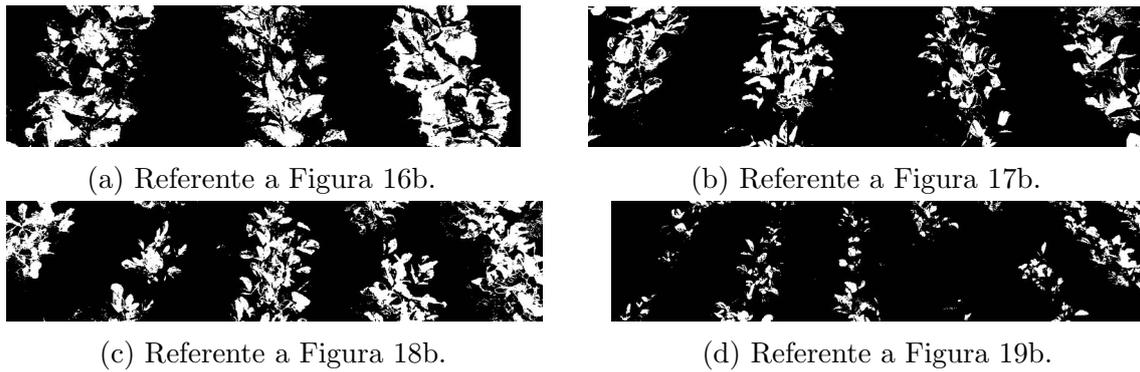


Figura 20: Segmentação do verde.

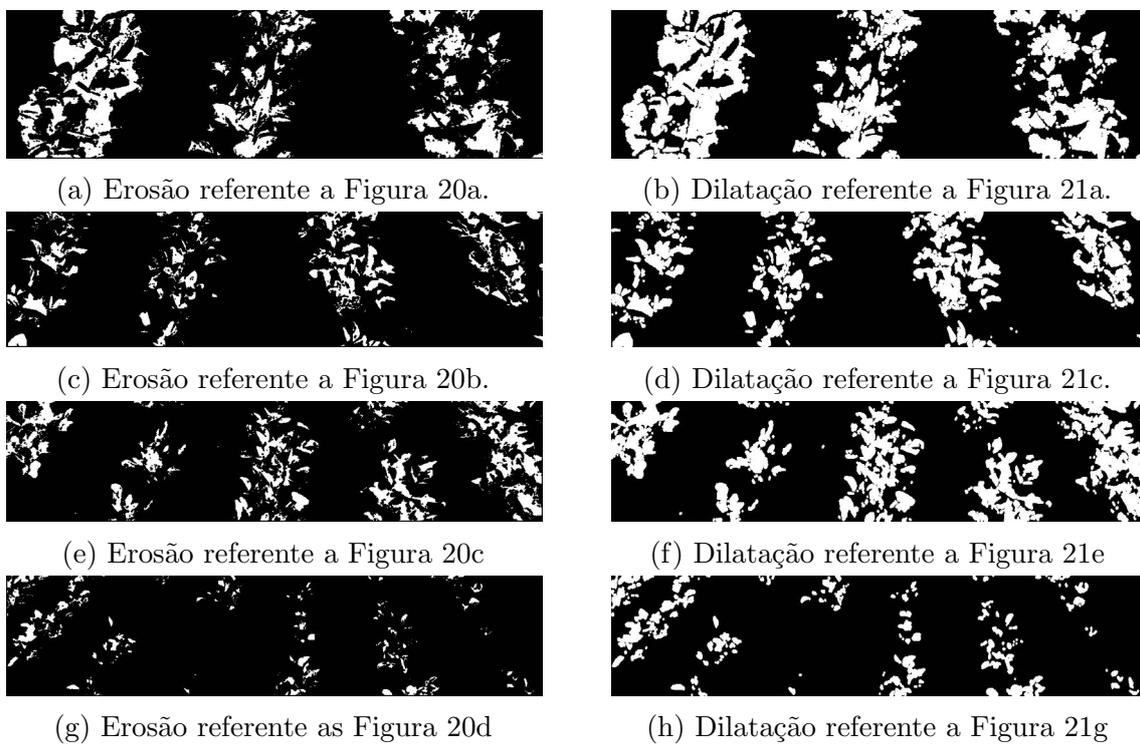


Figura 21: Erosão e dilatação.

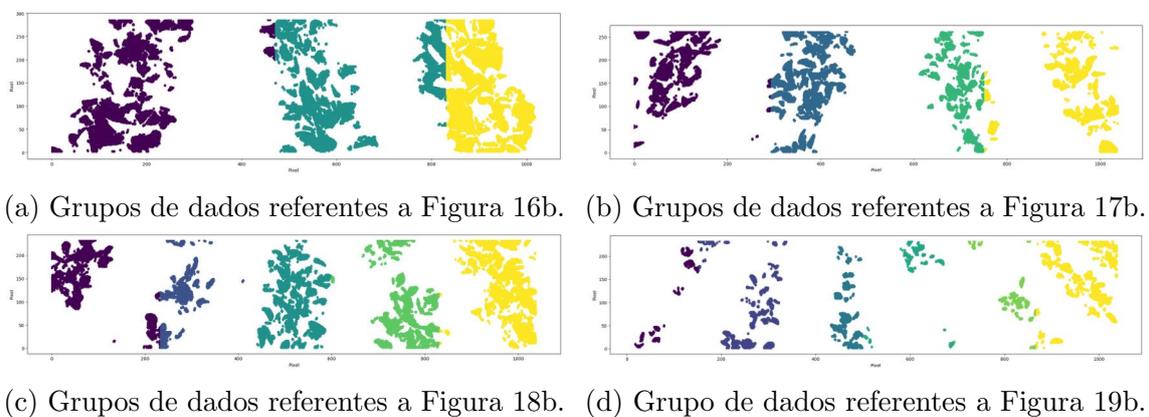
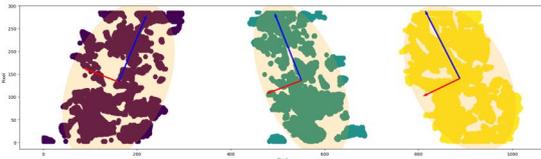
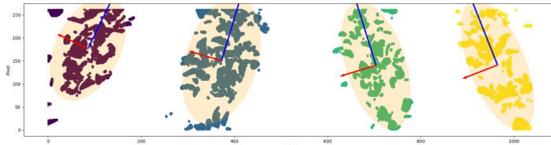


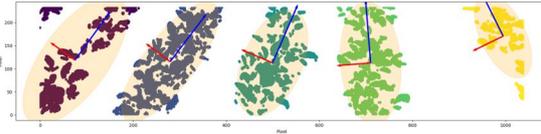
Figura 22: Resultado do particionamento inicial para dados com três, quatro, cinco e seis linhas de plantação.



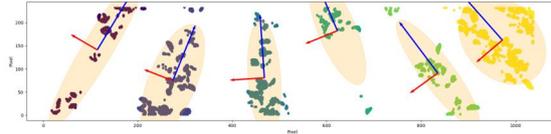
(a) Resultado final da execução do EM referente a Figura 22a.



(b) Resultado final da execução do EM referente a Figura 22b.



(c) Resultado final da execução do EM referente a Figura 22c.



(d) Resultado final da execução do EM referente a Figura 22d.

Figura 23: Resultado final da execução do EM para conjunto de dados com três, quatro, cinco e seis linhas de plantação.



(a) As linhas identificadas é o resultado final do EM que pode ser visto na Figura 23a.



(b) As linhas identificadas é o resultado final do EM que pode ser visto na Figura 23b.



(c) As linhas identificadas é o resultado final do EM que pode ser visto na Figura 23c.



(d) As linhas identificadas é o resultado final do EM que pode ser visto na Figura 23d.

Figura 24: Resultado final para identificação das linhas com três, quatro, cinco e seis linhas de plantação.

### 4.3 Métricas para mensurar a qualidade dos resultados

Esta seção tem por objetivo apresentar as métricas de avaliação da qualidade das retas que foram identificadas pelo algoritmo com as retas que foram marcadas manualmente para esta avaliação. A primeira métrica utilizada é a área entre as retas manual e automática. A segunda medida é o ângulo entre dois vetores. Por fim, a terceira forma de medir é a distância entre dois pontos.

O objetivo das métricas ter um parâmetro do resultado obtido pelo método proposto, saber o quão preciso é a identificação das linhas, se a identificação compromete uma aplicação.

#### 4.3.1 Área entre as retas manual e automática

Para realizar o cálculo da área entre as retas, primeiro foi preciso definir quais coordenadas cartesianas que compõem cada uma das retas. As coordenadas no plano para as retas automáticas foram obtidas através do algoritmo e as coordenadas no plano para as retas manuais foram feitas manualmente de forma visual. A Figura 25 demonstra como ficou a linha com a marcação manual e com a identificação automática e Tabela 5 são as coordenadas das retas para uma imagem exemplo.

As retas que foram obtidas pela marcação manual tem a limitação por depender da anotação humana que muitas das vezes pode ser subjetiva, ou não ter a mesma precisão que um algoritmo. Mas mesmo assim a anotação manual dos pontos pode ser considerado com sendo uma boa referência de onde as linhas de colheita estão.

Um ponto importante aqui é que os pontos das retas automáticas que são utilizadas para fazer o cálculo da área, são um segmento de reta, e esse segmento é limitado pelo tamanho da RI. E as retas manuais, os pontos que formam as retas foram marcados em uma imagem de dimensões iguais ao RI.

Sempre que as retas manual e automático tiver um ponto de interseção dentro da RI, o polígono formado pelas retas é dividido em duas partes no ponto de encontro. O que significa que o cálculo da área total é a soma do cálculo das áreas dos dois polígonos. Por exemplo: na Tabela 6 estão os pontos que formam os polígonos, e na Tabela 7 estão os pontos que formam os polígonos divididos no ponto de interseção das retas. O polígono<sub>1</sub> esta dividido em duas partes na 7, como sendo o polígono<sub>1,1</sub> e o polígono<sub>1,2</sub> e esse processo se repete para as demais área que possuem pontos de interseção. No caso o polígono formado não possuir interseção dentro do RI o cálculo da área é feito com os 4 pontos que formam esse polígono, o  $P_1$ ,  $P_2$ ,  $P_3$  e  $P_4$ . Isso pode ser visto na Tabela 7 para o polígono<sub>4</sub>.

Ligando os extremos das duas retas que corresponde a mesma linha, tem-se o polígono e para calcular a sua área utilizou o Shoelace Algorithm ou o Algoritmo do Cadarço [Braden, 1986], o nome é por fazer a multiplicação cruzada das coordenadas.

Pontos Manuais		Pontos Automáticos	
Reta 1	(-25; 0)	Reta 1	(-11; 0)
	(152; 234)		(118; 234)
Reta 2	(180; 0)	Reta 2	(179; 0)
	(330; 234)		(340; 234)
Reta 3	(404; 0)	Reta 3	(402; 0)
	(472; 234)		(493; 234)
Reta 4	(631; 0)	Reta 4	(640; 0)
	(642; 234)		(644; 234)
Reta 5	(841; 0)	Reta 5	(877; 0)
	(792; 234)		(770; 234)
Reta 6	(1047; 0)	Reta 6	(1019; 0)
	(925; 234)		(955; 234)

Tabela 5: Pontos marcados manualmente e pontos obtidos automaticamente.

Polígonos	Pontos			
	$P_1(x, y)$	$P_2(x, y)$	$P_3(x, y)$	$P_4(x, y)$
1	(-25; 0)	(-11; 0)	(118; 234)	(152; 234)
2	(180; 0)	(179; 0)	(340; 234)	(329; 234)
3	(404; 0)	(402; 0)	(493; 234)	(472; 234)
4	(631; 0)	(640; 0)	(644; 234)	(641; 234)
5	(841; 0)	(877; 0)	(770; 234)	(792; 234)
6	(1040; 0)	(1019; 0)	(955; 234)	(925; 234)

Tabela 6: Pontos que formam os polígonos.

Com esse algoritmo, é possível determinar a área de um polígono simples cujos os vértices são descritos por suas coordenadas cartesianas no plano.

O conceito principal do método é dividir o polígono principal em  $n$  trapézios e multiplicar cruzado as coordenadas correspondentes para encontrar a área que circunda o polígono e subtrair dele os trapézios circundantes para encontrar a área do polígono. Este cálculo é feito usando a Equação 19, onde o  $A$  é a área, o  $n$  é o número de lados do polígono e  $(x_i, y_i)$  são os vértices do polígono.

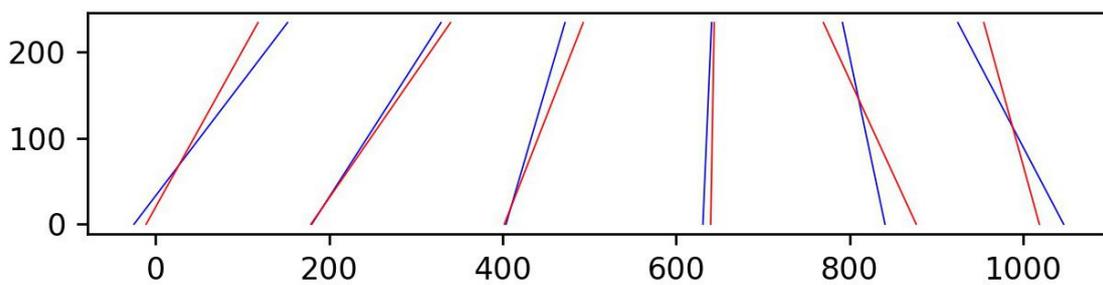
$$A = \frac{1}{2} \left| \sum_{i=1}^{n-1} x_i y_{(i+1)} + x_n y_1 - \sum_{i=1}^{n-1} x_{(i+1)} y_i - x_1 y_n \right| \quad (19)$$

Antes de fazer o cálculo das áreas é preciso saber quais conjuntos de pontos compõem a mesma e se as retas possuem interseção dentro da RI. Caso tenha intersecção das retas dentro da RI é dividido em duas as áreas e após, é feito o cálculo separado para cada uma delas e no final somando os dois valores das áreas para se ter o valor total.

Os valores das áreas da Tabela 7 de cima para baixo são referentes aos polígonos desenhados na Figura 26 são da esquerda para direita.



(a) Linhas marcadas na imagem.



(b) Apenas as linhas para melhor visualizar da dimensão das mesmas.

Figura 25: As linhas marcadas em azul são as marcações manuais e as linhas em vermelho foram obtidas automaticamente pelo algoritmo.

A Figura 27 é o desenho da área entre as retas manual e automático referentes as Figuras 16, 17, 18 e 19.

#### 4.3.2 Ângulo entre dois vetores

A segunda métrica de qualidade é o ângulo entre três pontos ou entre dois vetores. Dois pontos são os extremos inferiores da reta manual  $P_1$  e  $P_2$  da reta automática. O terceiro ponto o  $P_3$  é o ponto de intersecção das duas retas anteriores. Caso não exista intersecção entre as retas assume-se que o ângulo padrão é zero ou seja as retas são paralelas. A Figura 28 mostra geometricamente como é obtido o ângulo. Com esses ponto encontra-se os vetores  $\vec{v}_1$  e o  $\vec{v}_2$  conforme a Equação 20. Para realizar o cálculo do ângulo entre os dois vetores usa-se a Equação 21.

$$\begin{aligned}\vec{v}_1 &= P_1 - P_3 \\ \vec{v}_2 &= P_2 - P_3\end{aligned}\tag{20}$$

Polígonos	Pontos				Áreas	Total
	$P_1(x, y)$	$P_2(x, y)$	$P_3(x, y)$	$P_4(x, y)$		
1,1	(-25; 0)	(-11; 0)	(26,6; 68,3)		477,75	3295,5
1,2	(118; 234)	(152; 234)	(26,6; 68,3)		2817,75	
2,1	(180; 0)	(179; 0)	(192,5; 19,5)		9,75	1189,5
2,2	(340; 234)	(329; 234)	(192,5; 19,5)		1179,75	
3,1	(404; 0)	(402; 0)	(409,9; 20,4)		20,34	2263,68
3,2	(493; 234)	(472; 234)	(409,9; 20,4)		2243,34	
4	(631; 0)	(641; 234)	(644; 234)	(640; 0)	702	702
5,1	(841; 0)	(877; 0)	(810,5; 145,3)		2614,35	3590,7
5,2	(770; 234)	(792; 234)	(810,5; 145,3)		976,35	
6,1	(1040; 0)	(1019; 0)	(988,1; 112,9)		1581,5	3397
6,2	(955; 234)	(925; 234)	(988,1; 112,0)		1815,5	

Tabela 7: Pontos que formam os polígonos com suas respectivas áreas. Sempre que as retas manual e automática tiver intersecção dentro da RI o polígono é dividido em dois para realizar a cálculo das áreas. Por exemplo: o polígono<sub>1</sub> está dividido em dois, polígono<sub>1,1</sub> e polígono<sub>1,2</sub>.

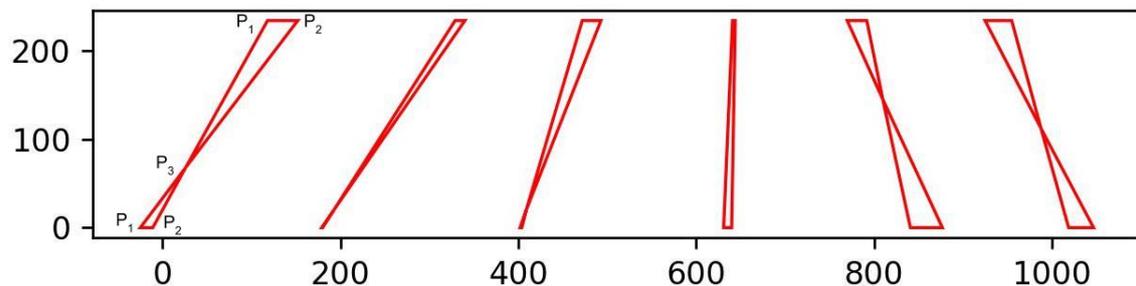


Figura 26: Desenho da forma dos polígonos.



(a) Área referente a Figura 16.



(b) Área referente a Figura 17.



(c) Área referente a Figura 18.



(d) Área referente a Figura 19.

Figura 27: Área entre as retas manual e automático.

$$\theta = \cos^{-1} = (\vec{v}_1 \vec{v}_2) / |\vec{v}_1| |\vec{v}_2| \quad (21)$$

A Tabela 8 reúne os ângulos que foram calculados referentes as retas da Figura 25. O *Primeiro* ângulo na tabela é referente ao primeiro conjunto de retas manual e automática da esquerda para direita, o mesmo processo se repete para os demais ângulos.

### 4.3.3 Distância entre dois pontos

A última medida de qualidade é a distância entre pontos extremos das retas. Os pontos que foram considerados são os extremos inferiores. Na Tabela 8 estão os pontos referentes a Figura 25 com o cálculo das suas distâncias. O cálculo foi feito utilizando o conceito de distância Euclidiana conforme a Equação 22. O ponto  $Pt1 = (x_1, y_1)$  é referente ao ponto manual e o ponto  $Pt2 = (x_2, y_2)$  é referente ao ponto automático, pontos esse contido na Tabela 8.

$$D_e = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}. \quad (22)$$

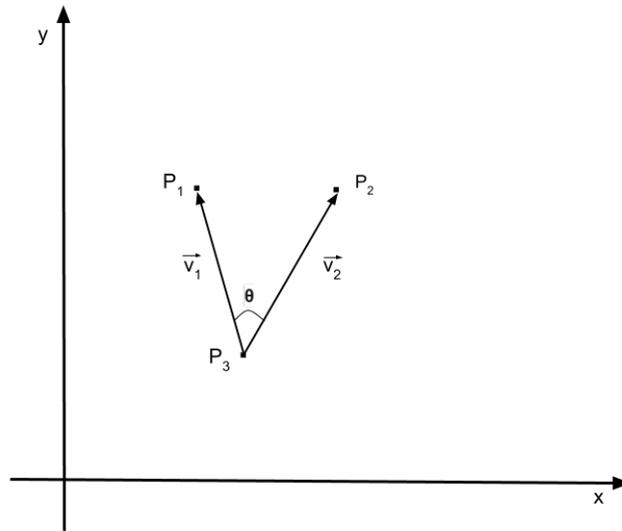


Figura 28: Representação geométrica de como é feito o cálculo do ângulo entre dois vetores.

	Ângulo em graus	Pontos		Distância em pixels
		Manual	Automático	
Linha 1	8,24	(-25; 0)	(-11; 0)	14
Linha 2	2,05	(180; 0)	(179; 0)	1
Linha 3	5,05	(404; 0)	(402; 0)	2
Linha 4	1,47	(631; 0)	(640; 0)	9
Linha 5	12,75	(841; 0)	(877; 0)	36
Linha 6	12,24	(1047; 0)	(1019; 0)	28

Tabela 8: Ângulo e as distâncias entre as retas manual e automático.

Polígonos	P1	P2	P3	Ângulo em graus
1	(-25; 0)	(-11; 0)	(26.6; 68.3)	8,24
2	(180; 0)	(179; 0)	(192.5; 19.5)	2,04
3	(404; 0)	(402; 0)	(409.9; 20.4)	5,04
4	(631; 0)	(641; 234)	(646; 351)	1,47
5	(841; 0)	(877; 0)	(810.5; 145,3)	12,7
6	(1040; 0)	(1019; 0)	(988.1; 112.9)	12,24

Tabela 9: P1 e P2 são pontos referentes a reta manual e a reta automática e P3 ponto de interseção e estes pontos são da Figura 25

Tabela 10: Distâncias entre as retas manual e automático.

Par de retas	Pontos		Distância em pixels
	Manual	Automático	
1	(-25,0)	(-11,0)	14
2	(180,0)	(179,0)	1
3	(404,0)	(402,0)	2
4	(631,0)	(640,0)	9
5	(841,0)	(877,0)	36
6	(1047,0)	(1019,0)	28

#### 4.4 Anotação dos dados para análise quantitativa

Para poder avaliar a qualidade das retas identificadas em números, foi desenvolvido uma ferramenta para poder anotar o resultado da identificação das linhas de plantação. A Figura 29 é a interface do software usado para a classificação de cada linha como *BOM*, *REGULAR* e *RUIM*. Cada uma das classificações é levando em conta se a identificação automática da linha faria a abertura correta do bico do pulverizador só se estiver sob um linha de plantação.

- *BOM* = a linha identificada é a mais próxima da linha de plantação onde a aplicação do produto é aplicado exatamente na linha.
- *REGULAR* = a linha identificada é regular, não é exatamente na linha de plantação mas a aplicação do produto não fica comprometida.
- *RUIM* = a linha identificada não condiz com a realidade, caso fosse aplicado o produto seria todo desperdiçado.

Uma parte do resultado da classificação pode ser visto na Figura 30. Ficou organizado por Nome da imagem, área, ângulo entre vetores, distância entre dois pontos, classificação e ângulo da reta em relação a coordenada cartesiana  $x$ .

#### 4.5 Análise quantitativa

Os dados classificados foram analisados para saber a média e o desvio padrão para as retas que foram classificadas como *BOM* e *REGULAR*. O resultado dessa análise pode ser visto na Tabela 11. A Tabela 11 está organizada como Média 1 e Desvio Padrão 1 para o ângulo menor que  $90^\circ$  e Média 2 e Desvio Padrão 2 para ângulo maior que  $90^\circ$ . A escolha do angulo de 90 graus para fazer essa divisão e por considerar que a linha de plantação ideal estaria no ângulo de 90 graus.

Importante notar que o ângulo em relação a coordenada cartesiana  $x$  é uma métrica de validação da linha detectada automaticamente sendo uma candidata à

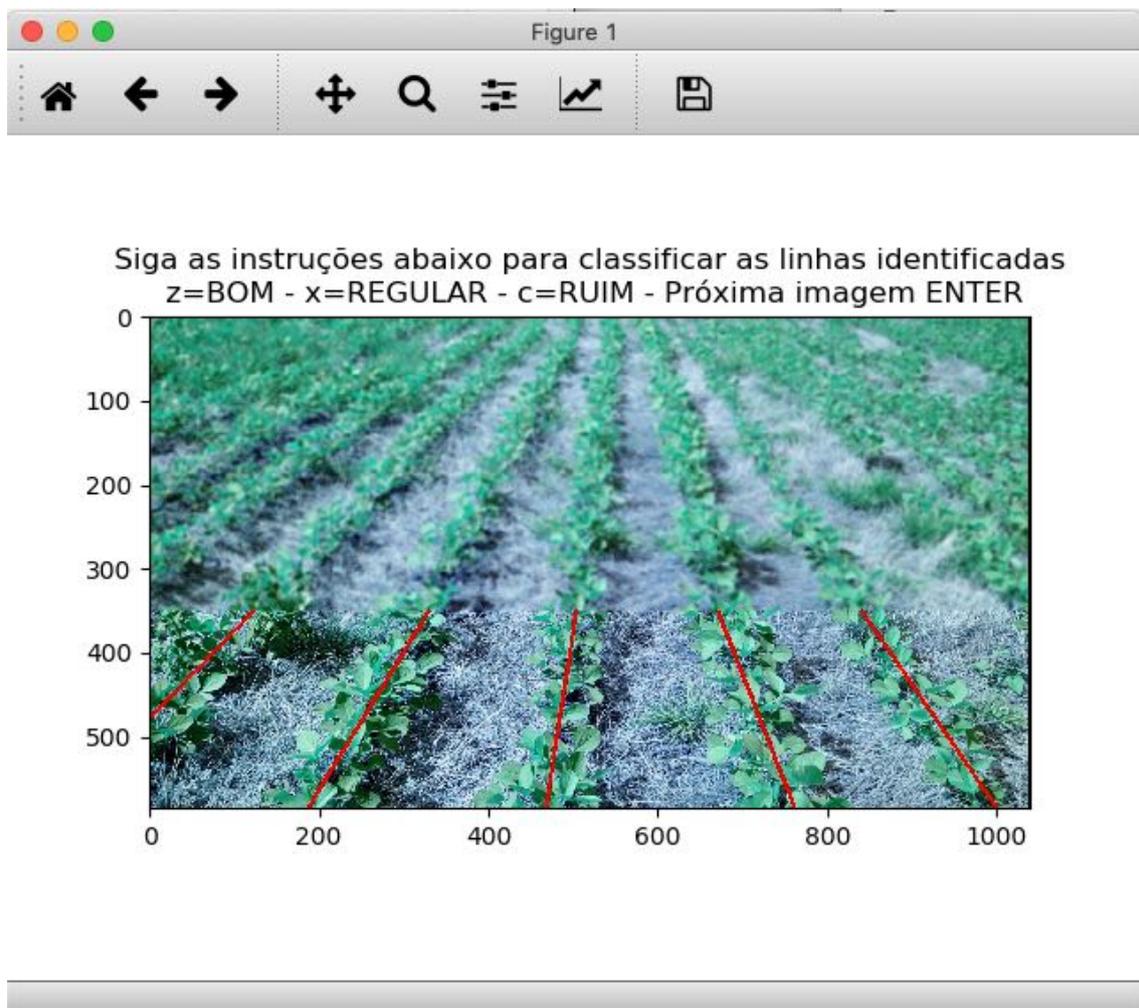


Figura 29: Interface do software para classificação dos dados.

## Classificação

	Nome	Área	Ângulo entre vetores	Distância	Classificação	Ângulo
0	IMG_149c.jpg	1547.0	6.782881642005424	19.0	bom	62.2776157547925
1	IMG_149c.jpg	2363.529411764706	9.871363117854212	6.0	bom	81.29777621005321
2	IMG_149c.jpg	3636.5945945945946	16.581223875928814	39.0	bom	109.9126609268484
3	IMG_149c.jpg	2206.0888888888889	8.165070306267523	22.0	bom	131.92254460057563
4	IMG_102.jpg	2691.0	3.8763095373012675	8.0	bom	58.03865658302297
5	IMG_102.jpg	468.0	0.8791933557390348	8.0	bom	70.90650799951439
6	IMG_102.jpg	117.0	0.4812584213216269	1.0	bom	82.69424046668918
7	IMG_102.jpg	351.0	0.7278225435761267	1.0	bom	95.12819104185284
8	IMG_102.jpg	2457.0	3.9504366127421804	24.0	bom	120.71103576609104
9	IMG_102.jpg	25619.118483412323	83.0232825143493	252.0	ruim	42.653125707512714
10	IMG_9.jpg	3011.044451500238	12.6508904366391	131.50285168010618	bom	45.99634789650493
11	IMG_9.jpg	1652.04	4.668966461489653	8.0	bom	58.57043438516149
12	IMG_9.jpg	117.0	0.23903748786750612	5.0	bom	81.2538377374448
13	IMG_9.jpg	585.0	1.0710468426223088	7.0	bom	111.25050550713325
14	IMG_9.jpg	936.0	1.356134214296901	13.0	bom	124.36278549070994
15	IMG_52.jpg	2385.0	2.985496129442705	7.0	bom	59.67639313745001
16	IMG_52.jpg	397.5	0.6412084618258973	8.0	bom	84.18239208310723
17	IMG_52.jpg	265.0	0.4078798931450558	3.0	bom	103.57747923690431
18	IMG_52.jpg	8314.747191011236	14.269036742923618	73.0	bom	127.17997400263572
19	IMG_144c.jpg	1227.0	1.8511117930769108	18.027756377319946	bom	51.53213668785245
20	IMG_144c.jpg	1314.0	4.43947697122959	12.0	bom	55.06068979532297
21	IMG_144c.jpg	2346.4285714285716	10.87412023711471	24.0	bom	90.52323458218419
22	IMG_144c.jpg	2844.8529411764707	12.30201628581574	22.0	bom	111.89156799496402

Figura 30: Resultado da classificação. Cada *Nome* que repete da imagem é referente à uma linha. A sequência de cima para baixo é a mesma sequência da esquerda para direita para as linhas.

	Média 1	Desvio Padrão 1	Média 2	Desvio Padrão 2
Área	2315,4	2190,4	2889,3	2276,9
Ângulo entre vetores	8,4	21,8	7,1	5,8
Distância	19,6	22,2	27,8	27,6
Ângulo	67,74	12,4	115,1	12,5

Tabela 11: Média e desvio padrão para os dados classificados como *BOM* e *REGULAR*

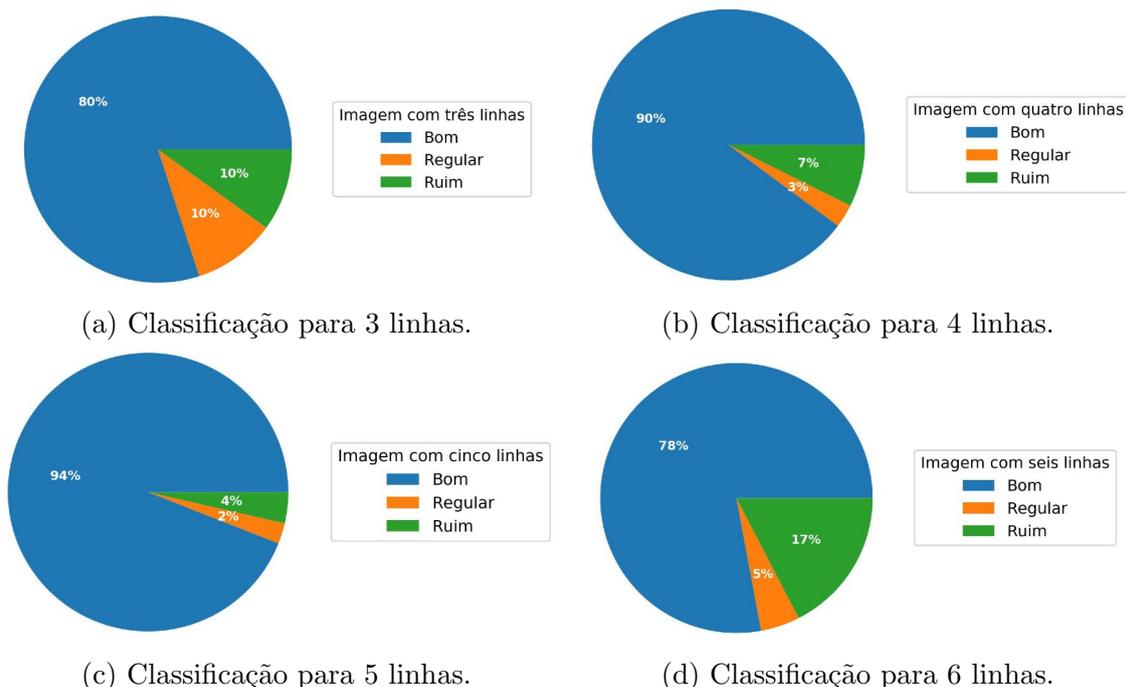


Figura 31: Resultado da classificação dividido por quantidade de linhas.

uma linha de plantação. Anteriormente na metodologia, a restrição dessa linha foi proposto de modo empírico e deveria estar entre os ângulo  $50^\circ$  e  $140^\circ$ . Analisando o resultado da classificação da Tabela 11 para a média e desvio padrão pode-se notar que restrição anterior é válida onde o ângulo levando em conta o erro em torno da média ficou entre  $55,34^\circ$  e  $102,5^\circ$ .

A Figura 31 reúne como ficou classificado o conjunto de dados proposto para três, quatro, cinco e seis linhas de plantação.

A Figura 32 mostra a porcentagem de sucesso na identificação das linhas para cada conjunto de imagens. Para imagens com 3, 4, 5 e 6 linhas, a porcentagem de acerto foi respectivamente de 90%, 93%, 96% e 83%, considera-se que as linhas classificadas como *BOM* e *REGULAR* foram identificadas com sucesso, isso significa que não compromete a aplicação do produto levando em conta que é preciso ter linhas de plantação para que o bico do pulverizador seja aberto. A Figura 33 apresenta a porcentagem de acerto para o algoritmo para o conjunto total de linhas e para o conjunto de imagens. Para o total de linhas, a precisão do algoritmo foi de 90% e

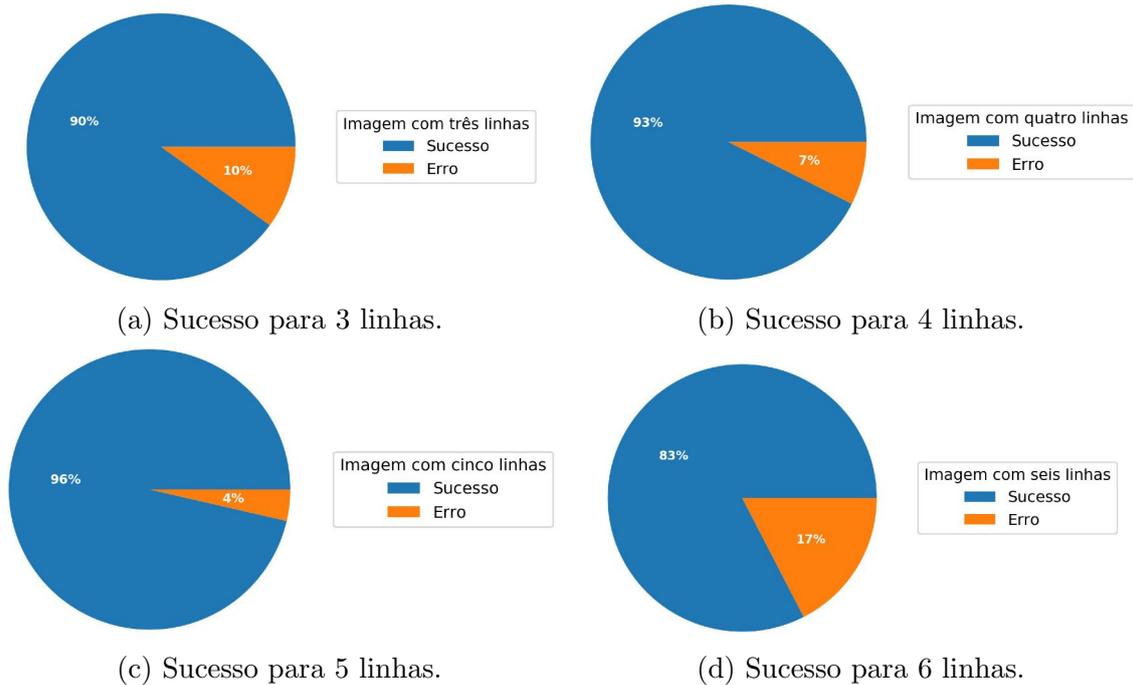


Figura 32: Porcentagem de acerto do algoritmo por conjunto de dados.

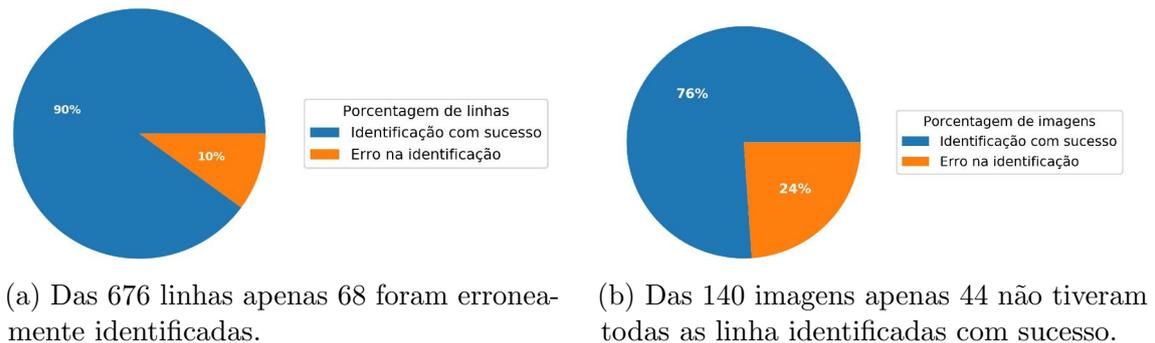


Figura 33: Porcentagem de acerto do algoritmo.

para o total de imagens onde todas as linhas foram identificadas corretamente foi de 76%.

## 4.6 Comparação do método proposto

O método proposto de identificação de linhas de cultura foi comparado com outros dois métodos. O primeiro método a se comparado foi proposto por Weber et al. (2018) e o segundo método foi proposto por Bakker et al. (2008).

Para pode comparar os método foi preciso implementar ambos algoritmos. A implementação foi feita utilizando a linguagem de programação Python e a biblioteca de visão computacional OpenCV.

Para avaliar os métodos foi utilizado mesmo conjunto de dados e as mesmas características usadas no método proposto. Isso quer dizer que a identificação das

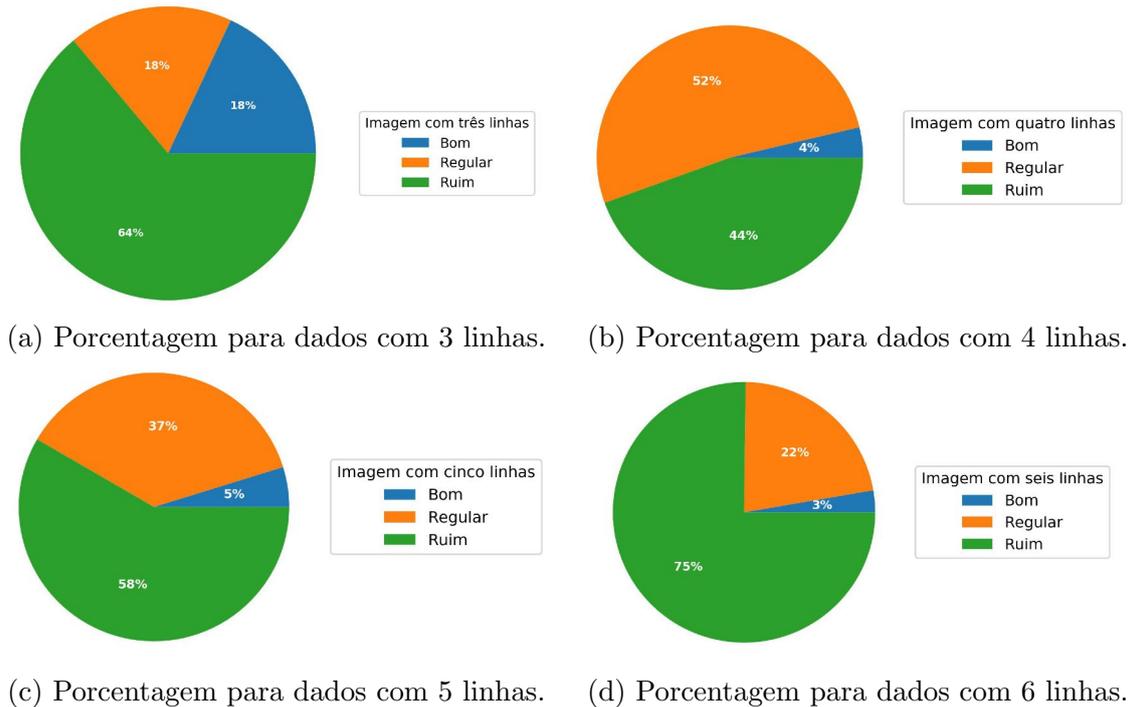


Figura 34: Dados classificados como *BOM*, *REGULAR* ou *RUIM* para o primeiro algoritmo.

linhas de cultura foram feitas utilizando a região de interesse.

O método proposto por Weber et al. (2018) utiliza o Excesso de Verde menos o Excesso de Vermelho menos o Excesso de Azul (*ExGRB*) [Underwood et al., 2015] para segmentar o verde da cultura e para identificação das linhas utiliza o Progressive Probabilistic Hough Transform (PPHT) [Matas et al., 2000].

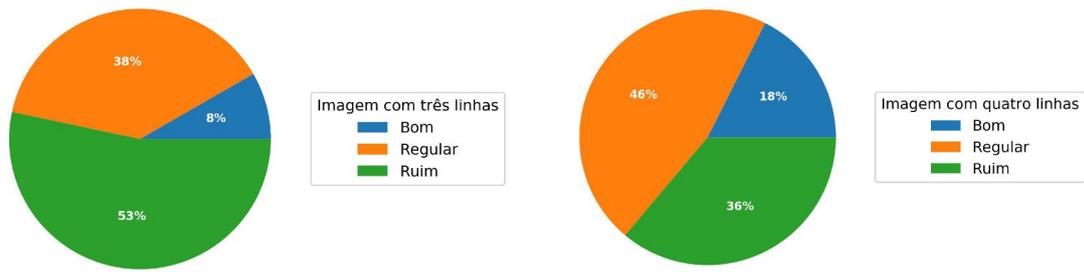
O outro método foi proposto por Bakker et al. (2008) utiliza o Excesso de Verde (*ExG*) [Woebbecke et al., 1995] para segmentar o verde dos dados e para a identificação das linhas foi utilizado o Standard Hough Transform (SHT) [Duda and Hart, 1971].

Ambos os métodos foram implementados e submetidos ao mesmo conjunto de dados. O resultado obtido dos algoritmos na identificação das linhas foi utilizado para classificação. Essa classificação seguiu o mesmo critério adotado anteriormente na Seção 4.4, onde, cada uma das linhas foram classificadas como sendo *BOM*, *REGULAR* ou *RUIM* para cada uma das linha de cultura identificadas.

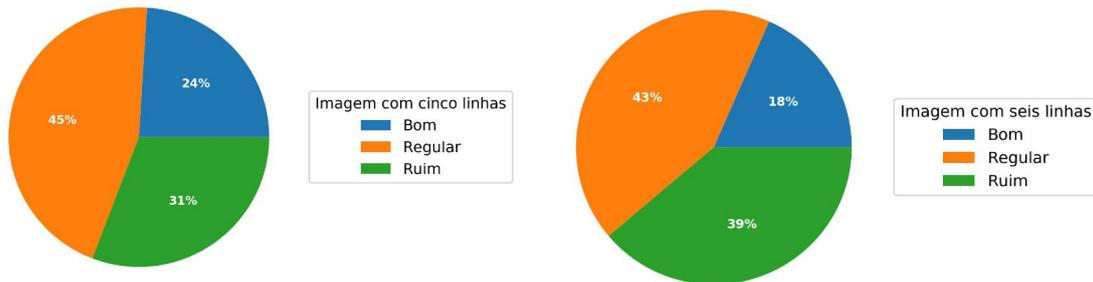
Com os dados classificados, foi feito uma análise levando em conta cada um dos parâmetros quantitativos da Seção 4.4 e por quantidade de linhas por imagens.

A Figura 34 mostra como ficou a classificação dos dados para o primeiro algoritmo que foi proposto por Weber et al. (2018) e a Figura 35 mostra como ficou a classificação dos dados para o segundo algoritmo que foi proposto por Bakker et al. (2008).

Considerando apenas linhas identificadas com sucesso, isso significa que as retas foram classificadas como sendo *BOM* e *REGULAR*. O método proposto por Weber

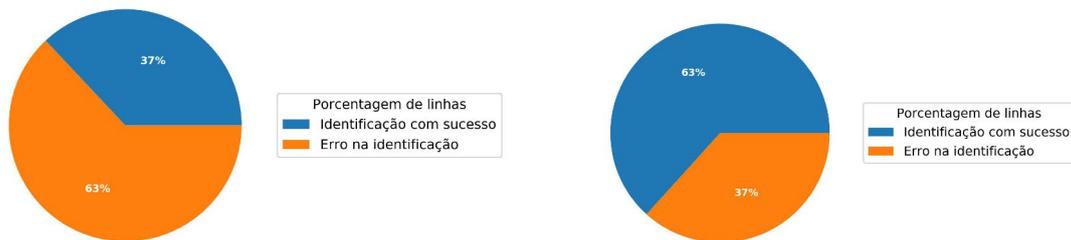


(a) Porcentagem para dados com 3 linhas. (b) Porcentagem para dados com 4 linhas.



(c) Porcentagem para dados com 5 linhas. (d) Porcentagem para dados com 6 linhas.

Figura 35: Dados classificados como *BOM*, *REGULAR* ou *RUIM* para o segundo algoritmo.

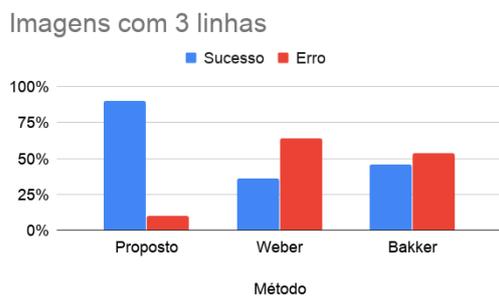


(a) Porcentagem para o primeiro algoritmo. (b) Porcentagem para o segundo algoritmo.

Figura 36: Dados classificados como *BOM*, *REGULAR* são considerados que tiveram sucesso na identificação.

et al. (2018) teve 37% classificado com sucesso e método proposto por Bakker et al. (2008) foi de 63% classificado com sucesso. Ambos o métodos tiveram uma identificação inferior ao método apresentado que foi de 90% das linhas classificadas com sucesso. O resultado pode ser visto na Figura 36.

A Figura 37 compara o método proposto com o método de Weber et al. (2018) e de Bakker et al. (2008). A comparação é feita em relação ao sucesso na identificação das linhas ou se não foram identificadas corretamente. Como explicado anteriormente as linhas que são identificadas com sucesso são as que não comprometem a aplicação do produto. Como pode ser visto na Figura 37 o método proposto supera os dois métodos comparados na porcentagem de linhas identificadas com sucesso.



(a) Porcentagem para imagens com três linhas.



(b) Porcentagem para imagens com quatro linhas.



(c) Porcentagem para imagens com cinco linhas.



(d) Porcentagem para imagens com seis linhas.

Figura 37: Porcentagem de linhas identificadas com sucesso ou erro na identificação das linhas para o método proposto e para os dois métodos que foram comparados.

## 5 CONCLUSÃO

Foi proposto um novo algoritmo baseado no EM para a identificação de linhas de cultura. O mesmo demonstrou uma maior eficiência na identificação das linhas para o dataset em comparação com os métodos de Weber et al. (2018) e Bakker et al. (2008).

A segmentação foi eficiente identificando diferentes tons de verde embora ajustar o  $k$  e o  $t$  seja difícil.

Os dados resultantes da segmentação foram classificados como modelo de mistura Gaussiana, o que possibilitou estimar a incerteza para cada pixel associado a cada conjunto, tornando-se possível uma nova abordagem para identificação das linhas de plantação utilizando o algoritmo probabilístico Expectation Maximization. O EM foi muito efetivo na reorganização dos dados seguindo a premissa que cada cluster tem os pixels com maior probabilidade de pertencimento.

O trabalho apresentou um método de identificação das linhas de cultivo para dados com três até seis linhas. O que possibilitou a identificação das linhas com diferentes quantidades foi a utilização do EM, o que após o final da execução do algoritmo, os clusters foram reorganizados de modo que todos os dados pertencentes a eles são os que possuem maior probabilidade. E em consequência disso, foi possível utilizar o conceito de variância para os dados e encontrar o autovetor principal que com ele obter as linhas de cultivo.

As métricas propostas para avaliar se as linhas identificadas e se elas correspondem as linhas de plantação se mostraram eficientes. O conceito de ponto de fuga e o ângulo de inclinação só foi possível a utilização por causa da característica de captura dos dados em perspectiva onde todos os dados foram capturados com ângulo que inclinação em relação ao terreno. A outra medida foi o ângulo de inclinação em relação ao eixo coordenado  $x$ . Esta medida está ligada à perspectiva dos dados onde o resultado das linhas identificadas tem um padrão de inclinação ficando entre os  $50^\circ$  e  $140^\circ$ . Essas duas métricas se mostram satisfatórias para avaliar se a linha identificada pelo algoritmo corresponde há uma linha válida.

A áreas entre as retas manual e automáticas, o ângulo entre dois vetores, a

distancia entre dois pontos extremos são uma boa abordagem para medir a qualidade das linhas identificadas. A limitação se dá pelo fato que é preciso ter uma referência, no caso marcação manual das linhas de plantação.

O método proposto em relação aos métodos avaliados foi superior na identificação das linhas de colheita para o conjunto de dados utilizado.

Por fim, com base nas métricas para medir a qualidade da identificação das linhas de plantação, o algoritmo teve um aproveitamento de 90% de sucesso na identificação de linhas de plantação e um aproveitamento de 76%, considerando que todas as linhas por imagem tiveram a identificação correta.

## 5.1 Trabalhos futuros

Para trabalhos futuros sugere-se a implementação dos seguintes itens:

- Contagem automática do número de linhas de plantação.
- O algoritmo ser capaz de alterar os valores dos parâmetros de  $k$  e  $t$ .
- Resolver a limitação de ter que fazer a marcação manual para medir a qualidade das linhas de plantação.
- Avaliar um conjunto maior de dados.
- Melhorar o tempo de resposta do algoritmo.

## REFERÊNCIAS

T. Bakker, H. Wouters, K. Van Asselt, J. Bontsema, L. Tang, J. Müller, and G. van Straten. A vision based row detection system for sugar beet. *Computers and electronics in agriculture*, 60(1):87–95, 2008.

C. M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.

B. Braden. The surveyor’s area formula. *The College Mathematics Journal*, 17(4): 326–337, 1986. ISSN 07468342, 19311346. URL <http://www.jstor.org/stable/2686282>.

R. O. Duda and P. E. Hart. Use of the hough transformation to detect lines and curves in pictures. Technical report, Sri International Menlo Park Ca Artificial Intelligence Center, 1971.

EMBRAPA. EMBRAPA empresa brasileira de pesquisa agropecuária. <https://www.embrapa.br>. Acessado: 2019-08-15.

C. Ferreira, M. Camargo, and C. Vegro. Defensivos agrícolas: comercialização recorde em 2011 e expectativas de acréscimo nas vendas em 2012. *Análises e Indicadores do Agronegócio*, 7(7):1–5, 2012.

I. D. García-Santillán, M. Montalvo, J. M. Guerrero, and G. Pajares. Automatic detection of curved and straight crop rows from images in maize fields. *Biosystems Engineering*, 156:61–79, 2017.

P. M. Granitto, P. F. Verdes, and H. A. Ceccatto. Large-scale investigation of weed seed identification by machine vision. *Computers and Electronics in Agriculture*, 47(1):15–24, 2005.

D. D. Grützmacher, A. D. Grützmacher, D. Agostinetto, A. E. Loeck, R. Roman, S. C. Peixoto, and R. Zanella. Monitoramento de agrotóxicos em dois mananciais hídricos no sul do brasil. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 12(6):632–637, 2008.

- J. M. Guerrero, M. Guijarro, M. Montalvo, J. Romeo, L. Emmi, A. Ribeiro, and G. Pajares. Automatic expert system based on images for accuracy crop row detection in maize fields. *Expert Systems with Applications*, 40(2):656–664, 2013.
- M. Guijarro, G. Pajares, I. Riomoros, P. Herrera, X. Burgos-Artizzu, and A. Ribeiro. Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture*, 75(1):75–83, 2011.
- T. Hague, N. D. Tillett, and H. Wheeler. Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 7(1):21–32, 2006.
- Jacto. Jacto máquinas e implementos agrícolas. <http://www.jacto.com.br>. Acesso: 2019-08-30.
- T. Kataoka, T. Kaneko, H. Okamoto, and S. Hata. Crop growth estimation system using machine vision. In *Proceedings 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2003)*, pages b1079–b1083 vol.2, 2003.
- J. A. Marchant and C. M. Onyango. Shadow-invariant classification for scenes illuminated by daylight. *J. Opt. Soc. Am. A*, 17(11):1952–1961, 2000.
- J. A. Marchant and C. M. Onyango. Color invariant for daylight changes: relaxing the constraints on illuminants. *J. Opt. Soc. Am. A*, 18(11):2704–2706, 2001.
- J. A. Marchant, N. Tillett, and C. M. Onyango. Dealing with color changes caused by natural illumination in outdoor machine vision. *Cybernetics and Systems: An International Journal*, 35(1):19–33, 2004.
- J. Matas, C. Galambos, and J. Kittler. Robust detection of lines using the progressive probabilistic hough transform. *Computer Vision and Image Understanding*, 78(1):119–137, 2000.
- G. E. Meyer and J. C. Neto. Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2):282 – 293, 2008.
- M. Montalvo, G. Pajares, J. M. Guerrero, J. Romeo, M. Guijarro, A. Ribeiro, J. J. Ruz, and J. Cruz. Automatic detection of crop rows in maize fields with high weeds pressure. *Expert Systems with Applications*, 39(15):11889–11897, 2012.
- C. M. Onyango and J. Marchant. Segmentation of row crop plants from weeds using colour and morphology. *Computers and electronics in agriculture*, 39(3):141–155, 2003.

- N. Otsu. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1):62–66, 1979.
- B. B. Pedersen. *Weed density estimation from digital images in spring barley*. PhD thesis, Royal Veterinary and Agricultural University, Department of Agricultural Sciences, Section of AgroTechnology, 2001.
- A. Resende, L. S. Shiratsuchi, M. d. F. VILELA, A. COELHO, E. CORAZZA, R. Y. Inamasu, A. d. C. BERNARDI, L. H. Bassoi, and J. d. M. NAIME. Agricultura de precisão no brasil: avanços, dificuldades e impactos no manejo e conservação do solo, segurança alimentar e sustentabilidade. In *Embrapa Pecuária Sudeste-Artigo em anais de congresso (ALICE)*. In: REUNIÃO BRASILEIRA DE MANEJO E CONSERVAÇÃO DO SOLO E DA ÁGUA, 18., 2010 . . . , 2010.
- A. Ribeiro, C. Fernández-Quintanilla, J. Barroso, and M. García-Alegre. Development of an image analysis system for estimation of weed pressure. *Precision agriculture*, 5(5):169–174, 2005.
- M. L. Ribeiro, C. Lourencetti, S. Y. Pereira, M. R. R. d. Marchi, et al. Contaminação de águas subterrâneas por pesticidas: avaliação preliminar. *Química Nova*, 2007.
- J. Romeo, G. Pajares, M. Montalvo, J. Guerrero, M. Guijarro, and A. Ribeiro. Crop row detection in maize fields inspired on the human visual perception. *The Scientific World Journal*, 2012(1):484390–484398, 2012.
- J. Romeo, G. Pajares, M. Montalvo, J. Guerrero, M. Guijarro, and J. de la Cruz. A new expert system for greenness identification in agricultural images. *Expert Syst. Appl.*, 40(6):2275–2286, 2013.
- Rometron. Rometron intelligent agricultural solutions. <https://www.rometron.nl>. Acessado: 2019-09-18.
- F. Rovira-Más, Q. Zhang, J. Reid, and J. Will. Hough-transform-based vision algorithm for crop row detection of an automated agricultural vehicle. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 219(8):999–1010, 2005.
- P. K. Sen. Estimates of the regression coefficient based on kendall’s tau. *Journal of the American statistical association*, 63(324):1379–1389, 1968.
- H. Thiel. A rank-invariant method of linear and polynomial regression analysis, part 3. In *Proceedings of Koninklijke Nederlandse Akademie van Wetenschappen A*, volume 53, pages 1397–1412, 1950.

- L. F. Tian and D. C. Slaughter. Environmentally adaptive segmentation algorithm for outdoor image segmentation. *Computers and electronics in agriculture*, 21(3):153–168, 1998.
- J. Underwood, M. Calleija, Z. Taylor, C. Hung, J. Nieto, R. Fitch, and S. Sukkarieh. Real-time target detection and steerable spray for vegetable crops. In *Proceedings of IEEE ICRA, workshop on robotics in agriculture*, 2015.
- F. Weber, G. Rosa, F. Terra, A. Oldoni, and P. Drews. A low cost system to optimize pesticide application based on mobile technologies and computer vision. In *2018 Latin American Robotic Symposium, 2018 Brazilian Symposium on Robotics (SBR) and 2018 Workshop on Robotics in Education (WRE)*, pages 345–350. IEEE, 2018.
- W. Winterhalter, F. V. Fleckenstein, C. Dornhege, and W. Burgard. Crop row detection on tiny plants with the pattern hough transform. *IEEE Robotics and Automation Letters*, 3(4):3394–3401, 2018.
- D. M. Woebbecke, G. E. Meyer, K. Von Bargen, and D. Mortensen. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1):259–269, 1995.
- X. Zhang, X. Li, B. Zhang, J. Zhou, G. Tian, Y. Xiong, and B. Gu. Automated robust crop-row detection in maize fields based on position clustering algorithm and shortest path method. *Computers and electronics in agriculture*, 154:165–175, 2018.