

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Pedro Ventura de Oliveira

Detecção de Linhas e Falhas de Plantio por meio da Associação de um Algoritmo Genético para Multilimiarização à Transformada Discreta de Wavelet e Transformada de Hough Probabilística e como Mobile Cloud Computing pode Auxiliar na Melhoria de Desempenho

Uberlândia, Brasil

2020

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Pedro Ventura de Oliveira

Detecção de Linhas e Falhas de Plantio por meio da Associação de um Algoritmo Genético para Multilimiarização à Transformada Discreta de Wavelet e Transformada de Hough Probabilística e como Mobile Cloud Computing pode Auxiliar na Melhoria de Desempenho

Dissertação de Mestrado apresentada à Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido à obtenção do título de Mestre em Ciências.

Área de Concentração: Inteligência Artificial

Linha de Pesquisa: Visão Computacional

Orientador: Prof. Dr. Luciano Vieira Lima

Universidade Federal de Uberlândia – UFU

Faculdade de Engenharia Elétrica – FEEL

Mestrado em Engenharia Elétrica

Uberlândia, Brasil

2020

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU com dados informados pelo(a) próprio(a) autor(a).

O48
2020 Oliveira, Pedro Ventura de, 1993-
Detecção de Linhas e Falhas de Plantio por meio da Associação de um Algoritmo Genético para Multilimiarização à Transformada Discreta de Wavelet e Transformada de Hough Probabilística e como Mobile Cloud Computing pode Auxiliar na Melhoria de Desempenho [recurso eletrônico] / Pedro Ventura de Oliveira. - 2020.

Orientador: Luciano Vieira Lima.

Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Engenharia Elétrica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2020.685>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia elétrica. I. Lima, Luciano Vieira, 1960-, (Orient.). II. Universidade Federal de Uberlândia. Pós-graduação em Engenharia Elétrica. III. Título.

CDU: 621.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Pedro Ventura de Oliveira

Detecção de Linhas e Falhas de Plantio por meio da Associação de um Algoritmo Genético para Multilimiarização à Transformada Discreta de Wavelet e Transformada de Hough Probabilística e como Mobile Cloud Computing pode auxiliar na melhoria de desempenho

Dissertação de Mestrado apresentada à Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido à obtenção do título de Mestre em Ciências.

Banca Examinadora:

Prof. Dr. Luciano Vieira Lima (Orientador – UFU)

Prof. Dr. Keiji Yamanaka (Examinador – UFU)

Prof. Dra. Junia Magalhães Rocha (Examinadora – IFTM)

A Bolsa de Estudos para esta pesquisa foi concedida pela CAPES – Brasil.

Uberlândia, Brasil

2020

ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Dissertação de Mestrado Acadêmico, 751, PPGEELT				
Data:	Treze de outubro de dois mil e vinte	Hora de início:	15:00	Hora de encerramento:	17:30
Matrícula do Discente:	11722EEL008				
Nome do Discente:	Pedro Ventura de Oliveira				
Título do Trabalho:	Detecção de Linhas e Falhas de Plantio por meio da Associação de um Algoritmo Genético para Multilimiarização à Transformada Discreta de Wavelet e Transformada de Hough Probabilística e como Mobile Cloud Computing pode auxiliar na melhoria de desempenho.				
Área de concentração:	Processamento da informação				
Linha de pesquisa:	Inteligência Artificial				
Projeto de Pesquisa de vinculação:	Título: VORTAL_Agência Financiadora: _MCT&I_Início__/_/_Término _EM ANDAMENTO_No. do Projeto na agência: DIPOC 524/11, Fonte 0100.000000 – Gestora: 762 – PTRES: 021558 - Processo 01200.004541/2011 – 84. Professor Coordenador: LUCIANO VIEIRA LIMA				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Keiji Yamanaka - FEELT/UFU; Junia Magalhães Rocha - IFTM; Luciano Vieira Lima - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Luciano Vieira Lima, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de **Mestre**.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Keiji Yamanaka, Professor(a) do Magistério Superior**, em 14/10/2020, às 13:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luciano Vieira Lima, Presidente**, em 14/10/2020, às 20:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Junia Magalhães Rocha, Usuário Externo**, em 15/10/2020, às 08:19, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2274081** e o código CRC **99C7D2D7**.

AGRADECIMENTOS

Inicio meus agradecimentos pela minha nova família: Graziely Borges Oliveira, meu porto seguro e quem sempre me impulsionou a ir adiante e persistir naquilo que desejo conquistar. Sem você, muito do que me tornei não existiria, e sou muito feliz pelo que venho me tornado.

Agradeço a minha mãe, Maria Tereza Ventura, e minha irmã, Paula Ventura, pelo constante apoio. A distância fortaleceu nossos laços e nossos laços me ensinaram muito sobre amor, bondade e entrega ao que acreditamos.

Sou grato também pelos meus amigos que sempre me acompanharam em minhas jornadas da maneira que lhes era possível, em especial, Mariana Dias, Isabela Masini, Allan Muro e Georges Dib. Sem vocês, os dias seriam mais pesados e menos engraçados, e a vida exige leveza para lidar com os momentos difíceis.

Um agradecimento especial à Camila Linhares por, além de desempenhar o papel de amiga, me auxiliar em diversos aspectos com o trabalho, tanto em sua construção quanto na atenção com as datas.

Ao demais membros de minha família sou grato por tudo que me ensinaram ao longo da minha vida e por acreditarem em mim, além de vibrarem com minhas conquistas.

Não em menor importância, sou extremamente grato ao meu orientador, Luciano Vieira Lima, o qual me ensinou, deu tempo ao meu tempo e não deixou de acreditar que havia potencial em mim. Tenho o carinho como o de um filho ao pai, no âmbito acadêmico, e a admiração como a de um fã ao seu querido artista, por toda a sua criatividade e intelecto, que tanto me inspiraram e me indicaram o melhor rumo para me tornar um bom mestre aos meus alunos e incentivá-los a crescer.

Por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de fomento, a qual foi de grande valia para o foco em meus estudos, além das demais pessoas que contribuíram direta ou indiretamente para a finalização deste trabalho.

RESUMO

No campo da Agricultura de Precisão uma questão que vem sendo tratada são as formas de detecção das linhas de plantio em imagens georreferenciadas, bem como falhas nesses sulcos da plantação. O presente trabalho propõe a detecção dessas linhas e falhas em uma plantação de cana-de-açúcar, pela aplicação de uma Transformada de Hough probabilística realizada após o pré-processamento de secções do ortomosáico por um método de segmentação baseada no uso de um Algoritmo Genético para multilimiarização, a partir da aplicação auxiliar prévia de uma Transformada Discreta de Wavelet aos histogramas dessas secções.

Além disso, é explorado, conceitualmente, como a integração da proposta ao paradigma de Mobile Cloud Computing pode melhorar o método em eficiência e acessibilidade dos dados produzidos. Com isso, propõe-se a integração futura da Mobile Cloud Computing, como forma de avançar tanto em eficiência do método, como em acessibilidade dos dados obtidos da plantação e melhorias que tornem a aplicação em Agricultura de Precisão uma prática ainda mais lucrável ao agricultor.

Estudos anteriores mostraram que experimentos utilizando diferentes imagens e abordagens de limiarização, por meio de testes comparativos, tem eficiência em velocidade e acurácia nos resultados o que corrobora com o método computacional proposto, sendo promissora sua aplicação para a definição das características de interesse em plantações.

O algoritmo computacional proposto demonstrou eficiência em sua performance, quando comparado com outras abordagens semelhantes, e é capaz de detectar com boa precisão as linhas e falhas em uma plantação de cana-de-açúcar utilizada para os testes experimentais. Desse modo, a aplicação futura do paradigma de Mobile Cloud Computing seria capaz de trazer ainda mais benefícios em sua eficiência geral, devido a robustez do sistema computacional que pode ser adotado.

Palavras-chave: Algoritmo Genético. Limiarização. Detecção de Linhas de Plantio.

Transformada Discreta de Wavelet. Transformada de Hough. Visão Computacional. Mobile Cloud Computing.

ABSTRACT

In the field of Precision Agriculture, an issue that has been addressed to it are ways of detecting crop rows in georeferenced images, as well as failure in these rows on the plantation. The present work proposes the detection of these lines and flaws in a sugarcane plantation by applying a probabilistic Hough Transform performed after the pre-processing of sections of this plantation's orthomosaic through a segmentation method based on the use of a Genetic Algorithm for multilimiarization , from the prior auxiliary application of a Discrete Wavelet Transform to the histograms of these sections.

Furthermore, it is explored, conceptually, how the integration of the proposal to the Mobile Cloud Computing paradigm can improve the method in efficiency and accessibility of the data produced. With this, it is proposed the future integration of Mobile Cloud Computing, as a way to advance in efficiency of the method, in accessibility of the data obtained from the plantation and improvements that make the application in Precision Agriculture an even more profitable practice for the farmer.

Previous studies have shown that experiments using different images and thresholding approaches, by means of comparative tests, are efficient in speed and accuracy on the results, which corroborates with the proposed computational method, and its application for the definition of the characteristics of interest in plantations is promising.

The proposed computational algorithm demonstrated efficiency in its performance, when compared with other similar approaches, and is capable of detecting with good precision the rows and flaws in the sugarcane plantation used for the experimental tests. In this way, a future application of the Mobile Cloud Computing paradigm would be able to bring even more benefits in its overall efficiency, due to the robustness of the computational system that can be adopted.

Keywords: Genetic Algorithm. Thresholding. Crop Rows Detection. Discrete Wavelet Transform. Computer Vision. Hough Transform. Mobile Cloud Computing.

LISTA DE ILUSTRAÇÕES

Figura 1. Exemplo de VANT's. Na parte superior, VANT M3 utilizado em mapeamento aéreo de áreas de plantio. Abaixo, modelo DJI Phantom 4, que pode ser utilizado para filmagens, por exemplo.	8
Figura 2. Exemplo de mosaico criado a partir de ortofotos.	11
Figura 3. Etapas de um sistema de visão computacional.	13
Figura 4. Métodos de segmentação de imagem.	14
Figura 5. Limiarização em dois níveis. Da esquerda para direita temos: imagem original, histograma da imagem e limiar selecionado (em vermelho), imagem limiarizada.	16
Figura 6. Representação de cromossomo como string binária.	18
Figura 7. Cruzamento proporcional. As setas vermelhas indicam os pontos onde o cruzamento ocorreu devido ao número aleatório ter se encaixado na taxa de cruzamento.	21
Figura 8. Ocorrência de mutação swap em cromossomo.	21
Figura 9. Exemplos de elementos estruturantes. Da esquerda para direita temos: cruz, quadrilátero 3x3, linha de comprimento 7, diamante 7x7. Os pontos pretos representam a origem.	24
Figura 10. Operações morfológicas: a) representa uma imagem binária; b) um elemento estruturante; c) é o resultado da dilatação da imagem pelo elemento; d) é o resultado da erosão; e) resultado do fechamento; f) resultado da abertura.	26
Figura 11. Processo para esqueletização de uma figura retangular.	27
Figura 12. Parâmetros ρ e θ da equação $\rho = x \cdot \cos\theta - y \cdot \sin\theta$	28
Figura 13. Espaço cartesiano e espaço de Hough. Uma reta no plano da imagem, correspondendo a um ponto no plano de Hough.	28
Figura 14. Arquitetura de MCC.	31
Figura 15. Taxonomia dos problemas relativos a MCC.	32
Figura 16. Fluxograma do funcionamento básico do algoritmo de detecção de linhas e falhas de plantio (continua)	34
Figura 17. (continuação) Fluxograma do funcionamento básico do algoritmo de detecção de linhas e falhas de plantio.	35
Figura 18. Recorte do ortomosaico em escala 1:500. As linhas de plantio são curvilíneas em maior ou menor grau, dependendo da área geográfica da porção da plantação.	36

Figura 19. Exemplo da fragmentação do ortomosáico em secções de igual tamanho.....	36
Figura 20. Exemplo de histograma utilizando 256 níveis da escala de cinza e a distribuição de pixels ao longo dos níveis.	38
Figura 21. Histograma reduzido após três convoluções ($r=3$)......	38
Figura 22. Representação do cromossomo, suas posições e seus limiares.....	39
Figura 23. Representação da operação de cruzamento.	40
Figura 24. Representação da operação de mutação.....	41
Figura 25. Representação do elitismo de 5% em população de 40 indivíduos. Melhores indivíduos da atual geração são enviados diretamente para a próxima.....	41
Figura 26. Fluxograma com ciclo do Algoritmo Genético ao receber histograma reduzido de uma secção.....	43
Figura 27. Fluxo do método computacional proposto e sua correspondência com relação as etapas de um sistema em visão computacional.....	47
Figura 28. Esquema de sistema de Mobile Cloud Computing associado à detecção de linhas e falhas de plantio.....	50
Figura 29. Imagens de teste em escala de cinza: Lenna (à esquerda) e Peppers (à direita).	54
Figura 30. Secção do ortomosáico utilizada para testes.....	56
Figura 31. Histograma em escala de cinza da secção utilizada do ortomosáico.....	56
Figura 32. Figura 31. Histograma em escala de cinza da secção utilizada do ortomosáico após a convolução com a TDW.....	57
Figura 33. Histograma em escala de cinza da secção do ortomosáico com limiares reconstituídos para escala original. O limiar em preto (144) representa aquele que será utilizado para binarização.	57
Figura 34. Passos do algoritmo: (a) conversão em escala de cinza; (b) binarização utilizando o limiar encontrado pelo AG;(c) operação morfológica de fechamento; (d) operação morfológica de erosão; (e) esquelitização; (f) THPP aplicada no esqueleto sob a imagem em escala de cor original da secção.	58
Figura 35. Retas contínuas produzidas após o refinamento dos segmentos gerados pela THPP.	59
Figura 36. Secção com linhas de plantio (em azul) e falhas (em vermelho) detectadas em sobreposição à imagem original.	59
Figura 37. Conexão de 4 secções da plantação e a detecção de suas linhas e falhas. Em amarelo, temos a demarcação dos limites de cada secção.....	60

Figura 38. Secções da plantação de cana-de-açúcar e identificação da janela auxiliar...61
Figura 39. Identificação de falsos positivos. Na imagem à direita, a falha detectada mais acima vai além do limite da mesma e, a falha mais abaixo deveria ser inexistente. A imagem à esquerda facilita a visualização das indicações. 62

LISTA DE TABELAS

Tabela 1. Método computacional proposto.....	47
Tabela 2. Informações dos softwares/hardwares utilizados na simulação.....	52
Tabela 3. Métodos, limiares e tempo para sua computação em imagens de teste.	54

Sumário

1	INTRODUÇÃO	1
1.1	Justificativa	4
1.2	Objetivos	5
1.3	Organização do Trabalho	5
2	FUNDAMENTAÇÃO TEÓRICA	7
2.1	Agricultura de Precisão	7
2.1.1	VANT's na Agricultura de Precisão	8
2.1.2	Processamento e mosaicamento de imagens de VANT's	10
2.2	Visão Computacional	12
2.2.1	Processamento Digital de Imagens	13
2.2.2	Limiarização	15
2.2.3	Algoritmos Genéticos	17
2.2.4	Transformada Discreta de Wavelet	22
2.2.5	Morfologia Matemática	24
2.2.6	Transformada de Hough	27
2.3	Mobile Cloud Computing	29
3	METODOLOGIA	34
3.1.1	Ortomosáico e sua fragmentação	35
3.2	Segmentação de imagem: limiarização e multilimiarização	37
3.3	Transformada Discreta de Wavelet	37
3.4	Algoritmo genético para multilimiarização	39
3.5	Os limiares e o processo morfológico de esqueletização	44
3.6	Transformada de Hough Probabilística Progressiva	45
3.7	Aprimoramento das linhas detectadas	45
3.8	Localizando as falhas de plantio	46

3.9	Revisão: Fluxo do sistema	46
3.10	Associação ao Mobile Cloud Computing	48
4	RESULTADOS E DISCUSSÕES	52
4.1	Análise do AG proposto	52
4.2	Análise da aplicação para a detecção de linhas e falhas de plantio.....	55
4.3	Apontamento de melhorias	60
5	CONCLUSÕES.....	64
	REFERENCIAS	66

1 INTRODUÇÃO

A agricultura de Precisão (AP) vem se desenvolvendo ao longo das décadas transformando o modo como são tratadas as plantações e todo os processos que as envolvem. Conceitualmente, a AP busca transformar um sistema de produção agrícola de modo a otimizar o retorno econômico fornecido, baseando-se no gerenciamento de dados da variação espaciais e temporais da unidade produtiva, contribuindo com a sustentabilidade, redução de insumos e aumento da eficiência da cultura (Brasil, 2014, p. 6).

O desenvolvimento e a adaptação de produtos tecnológicos para a agricultura estão intimamente ligados ao desenvolvimento e melhoria da AP. O surgimento e adoção do Sistema de Posicionamento Global (GPS) em maquinários agrícolas, o uso de Sistemas de Informação Geográfica (SIG's ou, em inglês, GIS's) para mapeamento, etc., bem como a aplicação de sensoriamento em campo, ativo e remoto, e a evolução na coleta e tratamento de dados, vem alavancando e aprimorando os sistemas agrícolas ao longo dos anos tanto no âmbito de sua variabilidade espacial quanto temporal (Zhang et al., 2002).

Com isso, o acompanhamento das lavouras tem se tornado uma tarefa cada vez menos dispendiosa, no que se refere a tempo e a mão-de-obra humana, por exemplo. E também tem se diminuído a necessidade de um acompanhamento presencial para que se obtenham informações constantes do que ocorre na produção (Tian et al., 2020). Com a estruturação e ferramentas adequadas, diversas características podem ser adquiridas, preparadas e extraídas para uma melhor e mais eficiente tomada de decisões (Zhang et al., 2002).

Nesse âmbito, a Visão Computacional agregada à AP é uma das ferramentas em constante aprimoramento que traz grandes benefícios ao agronegócio a partir de informações extraídas de imagens. Na área da Visão Computacional a AP já é, de longa data, tida como uma possibilidade em potencial para o processamento de dados imagéticos (Tillett, 1991) e vem sendo cada vez mais explorada no campo de zonas rurais. Dentre estudos e aplicações que fazem uso da visão computacional e do processamento de imagens digitais podem ser citados, relacionados à agricultura, a detecção de doenças em plantas (Polder et al., 2014; Camargo e Smith, 2009) e suas folhas (Rastogi et al., 2015), classificação de grãos (Paliwal et al., 2001), análise de estresse biótico (Behmann et al., 2013), inspeção e seleção de alimentos (Brosnan e Sun, 2002; Cubero et al., 2013; Wu e Sun, 2013; Zhang et al., 2014), estimativa de produção (Payne et al., 2013), dentre outros. Em todos eles, são apresentados resultados positivos da aplicação de tecnologias que associam visão computacional como um facilitador do processo,

indo tais resultados de semelhantes a superiores quando comparado com a aplicação de mão-de-obra humana para a coleta de dados.

De modo geral, tecnologias associadas à AP, tais como visão computacional, auxiliam na redução dos custos de uma plantação, automatizando-a e, conseqüentemente, diminuindo a necessidade de execução manual de algumas atividades (Barreda et al., 2009), o que tende a reduzir erros e alguns problemas por falha humana.

Das aplicações com Visão Computacional, além das supracitadas, uma outra questão trabalhada é a identificação de linhas de plantio. Com ela, a detecção de falhas no plantio, estimativa de produtividade, contagem de plantas/grãos em linhas efetivamente produtivas, dentre outros exemplos, podem, quando no tempo correto, possibilitar ao produtor a tomada de decisões quanto às regiões afetadas negativamente dando maior controle do crescimento adequado e otimização da plantação em toda a área para um melhor retorno. Além disso, as linhas de produção estão ligadas à guia de maquinário agrícola e robôs autônomos que trafegam na plantação para realização de diversas atividades.

Na literatura, encontram-se diversos métodos para as aplicações relativas a busca das linhas de plantio, como a associação de sensores e câmeras ao maquinário agrícola para uma varredura terrestre das características de interesse à abordagem (García-Santillán et al., 2017; Jiang et al., 2015; Søggaard e Olsen, 2003), ou a partir de câmeras manualmente posicionadas em pontos da plantação (Vidović et al. 2016; Ji e Qi, 2011) ou, ainda, utilizando de Veículos Aéreos Não-Tripulados (Quiroz et al., 2019), cujo mercado na agricultura vem aumentando fortemente ao longo dos anos (AUVSI, 2013).

Com a adoção dos Veículos Aéreos Não-Tripulados (VANT's) e sensores cada vez mais modernos trabalhando em alta resolução espectral, tem-se uma maior flexibilidade na coleta de dados, praticidade, qualidade, e diminuição de custos, ao compararmos com a coleta de imagem via satélite e aviões tripulados mais comumente empregados no campo (Zhang e Kovacs, 2012).

Mesmo com todos esses avanços com relação as tecnologias adotadas em lavouras, é crescente a necessidade de agilidade de acesso aos dados coletados, sua manipulação e da obtenção de resultados de interesse. O que traz, em paralelo, o aumento da demanda por portabilidade para que as informações de interesse possam ser produzidas e analisadas a qualquer momento, de qualquer lugar.

Tendo isso em vista a aquisição de imagens e determinação das linhas efetivas de plantio, é de interesse, tanto do provedor de serviços relacionados a AP quanto do cliente, o

processamento mobile e o desenvolvimento de sistemas que sejam ou tenham conectividade com sistemas mobile.

Atualmente, aplicações mobile em diversas áreas para fins econômicos, sociais e educacionais, por exemplo, tem aumentado por todo o mundo com um crescente número de usuários e plataformas (Allied Market Research, 2017). Entretanto, o processamento de dados imagéticos como os produzidos por VANT'S vai além das capacidades de hardware dos dispositivos móveis (tablets, smartphones e modelos menos robustos de notebooks), além de poder comprometer o armazenamento de dispositivos tanto para instalação de um software capaz de processar as imagens devidamente, quanto pelo próprio armazenamento das imagens a serem processadas.

Sendo assim, para a solução de processos com alta demanda de recursos de hardware – como CPU, memória e armazenamento –, a computação mobile (*mobile computing*) combinou-se com a computação em nuvem (*cloud computing*), utilizando-se de sua infraestrutura através da internet para o armazenamento e processamento de dados e criando o conceito de computação mobile em nuvem ou, em inglês, *mobile cloud computing* (Noor et al., 2018).

O presente trabalho busca o desenvolvimento de uma abordagem, utilizando Visão Computacional, para a identificação de linhas produtivas; e usar de imagens de uma plantação real, adquiridas por VANTS, para localizar as falhas de plantio. Para tanto, utiliza-se um método de pré-processamento das imagens através do desenvolvimento e aplicação combinada de técnicas em um Algoritmo Genético que possibilite um retorno rápido e de boa precisão dos resultados.

Partindo-se desse pré-processamento, um novo algoritmo computacional será desenvolvido e aplicado, complementando o anterior, para a detecção de linhas de produção e das áreas de falha nas linhas de plantio, baseando-se em morfologia matemática e na Transformada de Hough.

Será apresentado, por fim, através de uma análise sobre mobile cloud computing, os benefícios da integração desses conceitos ao sistema de AP voltado para a detecção de linhas de plantio, além de apresentar como o algoritmo desenvolvido pode interagir com esses sistemas para um retorno rápido – e sempre acessível – ao produtor dos dados de sua lavoura para a tomada de ações.

1.1 Justificativa

A visão computacional na agricultura de precisão vem se desenvolvendo em diversas frentes (como guia de maquinário, robôs autônomos, análise da vegetação do plantio, por exemplo) ao longo das décadas. Porém, ao analisarmos a base de dados da biblioteca digital *IEEE (IEEE Xplore Digital Library)*, a relação de pesquisas que envolvem a detecção de linhas de plantio (*crop rows/lines detection*) na AP e visão computacional não é tão extensa quanto em outras áreas.

Ao configurarmos os critérios de buscarmos utilizando as palavras-chaves: “*precision agriculture*” OR “*crop rows*” OR “*crop rows detection*” OR “*crop lines*” OR “*crop lines detection*”, temos um total de 46,553 resultados datados do período de 1875 – 2020. Desse total, 32,566 resultados estão compreendidos em 2010 – 2020.

Ao modificarmos a pesquisa para: “*precision agriculture*” OR “*crop rows*” OR “*crop rows detection*” OR “*crop lines*” OR “*crop lines detection*” AND “*computer vision*”, temos menos de um terço dos resultados totalizando 13,977 sendo 11,087 trabalhos no período de 2010 – 2019.

Ao especificarmos somente por trabalhos que envolvem linhas de plantio, desassociando o termo de busca “*precision agriculture*” o total de resultados cai para 12,777 sendo 10,136 entre 2010 – 2019. No entanto, embora esse valor ainda seja expressiva e grande parte da contribuição seja atual (dos últimos 9 anos), trabalhos utilizando drones/VANT’s na detecção de linhas de plantio ou com a finalidade delimitada à busca para falha de plantio não é expressiva.

As buscas “*precision agriculture*” OR “*crop rows*” OR “*crop rows detection*” OR “*crop lines*” OR “*crop lines detection*” AND “*drones*” e “*precision agriculture*” OR “*crop rows*” OR “*crop rows detection*” OR “*crop lines*” OR “*crop lines detection*” AND “*uav*”, retornam 638 e 955 resultados, respectivamente.

A pesquisa por associação de linhas de plantio à Algoritmos Genéticos ou Transformada de Hough somam 17 resultados e nem todos estão relacionados com o foco de interesse.

Quando relacionamos a agricultura de precisão à *mobile cloud computing* temos um número de 775 materiais, tratando de assuntos que podem integrar ou não, em maior ou menor parte, a busca por acesso aos dados capturados por VANT’s e o trato das informações imagéticas obtidas de forma prática e simplificada ao agricultor.

Embora o tema também tenha fontes em variado número de plataformas de pesquisa e desenvolvimento acadêmico, a revisão em busca de material na plataforma da *IEEE* revela que, mesmo com o expressivo aumento das pesquisas em AP nos últimos anos, ainda existem pontos que podem ser melhor explorados e aplicações que podem ser desenvolvidas visando o aperfeiçoamento e a inovação nas áreas no que diz respeito à engenharia e computação envolvida.

A busca, então, por um desenvolvimento em visão computacional utilizando dados imagéticos obtidos por VANT's para delimitação de linhas de produção e falhas no plantio e também de um estudo relacionando-o com dispositivos *mobiles* e *cloud* expressa uma contribuição relevante ao avanço e tendência de modernização tecnológica na indústria agrícola.

1.2 Objetivos

O presente trabalho tem como objetivo principal desenvolver e aplicar um método computacional capaz de detectar as linhas de plantio e determinar as regiões que apresentam falhas de plantio. Para esse fim, serão utilizadas imagens coletadas por um VANT voando em baixa altitude em plantação de cana-de-açúcar.

Para a detecção de tais linhas da lavoura, será feito uso da Transformada de Hough em imagens previamente preparadas e processadas. Esse pré-processamento será realizado utilizando técnica de segmentação de imagem, associada à Transformada Discreta de Wavelet em um Algoritmo Genético, e morfologia matemática.

Além disso, o trabalho tem por objetivo discorrer sobre os benefícios da integração da metodologia desenvolvido com o paradigma de *mobile cloud computing*, mostrando como pode ser feita a associação entre VANT, o algoritmo desenvolvido e dispositivos móveis interligados através de uma rede conectada à internet.

1.3 Organização do Trabalho

O trabalho está organizado da seguinte forma: no Capítulo 2 são apresentados os conceitos relevantes ao tema e que serão aplicados no desenvolvimento do trabalho; o Capítulo 3 discorre sobre a metodologia aplicada; o Capítulo 4 tratará dos resultados obtidos com relação a detecção de linhas de plantio e de suas falhas em uma lavoura de cana; o Capítulo 5 apresentará sobre a

associação da metodologia ao *mobile cloud computing*; por fim, o Capítulo 6 trará as conclusões do presente estudo com um tratamento final sobre os resultados e questões que podem ser correlacionadas em trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Nessa sessão serão tratados os conceitos relativos ao tema do trabalho, abordando questões gerais sobre o assunto e as ferramentas relevantes à proposta.

2.1 Agricultura de Precisão

Com o desenvolvimento e evolução das atividades agrícolas, a necessidade de um novo olhar sobre o manejo das lavouras também aumentou. A capacidade do agricultor de uma visão detalhada de sua área de agricultura diminui conforme o aumento dessas áreas e, embora haja um aumento das capacidades dos maquinários para o manejo das plantações, há também um aumento da variabilidade do solo e da cultura nessas áreas (Molin, 2015).

A Agricultura de Precisão, em busca da otimização da unidade produtiva, trata das questões de variabilidade a partir da aplicação de ferramentas e tecnologias adaptadas ao propósito (Brasil, 2014). As aplicações em tecnologia mudam o foco macro, considerando a cultura como sendo uniforme, de como os processos agrícolas eram realizados, para o manejo de pequenas áreas dentro da cultura de modo a melhor administrar as necessidades específicas de cada região do plantio (Shirish e Bhalerao, 2013).

Assim, busca-se o manejo mais consciente de defensivos agrícolas, água e outros recursos, corroborando com a sustentabilidade. Além disso, com um sistema de gerenciamento adequando e a junção entre lavoura e tecnologia, trazemos de volta o elemento principal para um cultivo eficiente, que é a informação (Shirish e Bhalerao, 2013), às mãos do agricultor.

De posse de informações consistentes, o produtor rural pode melhor atuar sobre a variabilidade espacial e temporal de sua cultura, administrando as particularidades de cada região. E para estabelecer informações consistentes, a coleta de dados é uma das partes primordiais.

No manejo da variabilidade utilizando AP, buscam-se dados como propriedades do solo, dados climáticos, pragas, doenças, ervas daninhas e produtividade (Coelho, 2005).

Atualmente, a coleta de dados com a utilização de sensoriamento remoto e visão computacional tem se desenvolvido em diversas dessas atividades, mas não limitadas a elas, estendendo-se, por exemplo, ao mapeamento, classificação de plantas, contagem e inspeção de alimentos e detecção de linhas de plantio. Para muitas dessas finalidades, como na identificação

de linhas de plantio, a análise de informações pode ser realizada a partir de imagens aéreas obtidas por VANT's, dentre outros métodos.

Independente da abordagem de coleta de dados, é importante salientar que o tratamento dos mesmos deve ocorrer de modo a retornar o posicionamento correto das regiões de uma cultura. Assim, é imprescindível o georreferenciamento dos dados (Grego et al., 2014) para que seu processamento gere informações consistentes para análise e correlação entre fatores temporais e espaciais da cultura.

2.1.1 VANT's na Agricultura de Precisão

O termo VANT expressa todo veículo aéreo não-tripulado que carregue uma carga útil (SDCI, 2017). No Brasil da década de 80 foram relatados os primeiros usos de VANT's, os quais tinham finalidade militar, mas sendo desativado na época e regressando apenas em 2007 (Jorge e Inamasu, 2014).

Figura 1. Exemplo de VANT's. Na parte superior, VANT M3 utilizado em mapeamento aéreo de áreas de plantio. Abaixo, modelo DJI Phantom 4, que pode ser utilizado para filmagens, por exemplo.



Fonte: <https://sensix.com.br/2016/03/09/o-que-e-um-vantdrone/>, acesso em julho, 2019.

No país, mesmo também com a tentativa de aplicação civil na época, os VANT's não tiveram muito sucesso tanto pela falta de mercado quanto pela falta de incentivo do governo

(Jorge e Inamasu, 2014), sendo os principais trabalhos ainda muito recentes e focados em aplicações civis como: inspeções de linhas de transmissão de energia, monitoramento, atividades de agrícolas, controle de pragas e queimadas (Medeiros, 2007).

Essa tecnologia vem ganhando seu espaço com os anos sendo cada vez mais expressiva como, por exemplo, em plantações, tendo em vista o constante aprimoramento da Agricultura de Precisão. A abertura é acompanhada da redução de custos relativo à implementação de tecnologias em engenharia aeroespacial e de sensoriamento (Abdullahi, 2015) que torna a implementação e as oportunidades cada vez mais viáveis.

Assim, no que diz respeito a AP, os VANT's têm capacidade para trabalhar com uma carga útil constituída por sensores como câmeras fotográficas, com infravermelho, multiespectrais e câmeras filmadoras (Fernandes, 2016), por exemplo.

O uso conjunto dessas técnicas tem proporcionado um baixo custo de aquisição de dados de alta resolução espacial quando comparados com técnicas de aquisição via satélite e por aeronaves tripuladas (Jensen, 2009) podendo auxiliar, por exemplo, na estimativa de produtividade e surgimento de pragas nas culturas (Shiratsuchi et al., 2014).

Nas imagens via satélite, por exemplo, temos que o custo e a disponibilidade para aquisição (nuvens, dentre outros elementos, podem atrapalhar a coleta) tende a limitar seu uso em aplicações de AP (Wu et al., 2007) e não trazem o mesmo nível de detalhamento – de poucos centímetros – que sensores acoplados a um VANT conseguem ter. Satélites nem tão pouco tem uma disponibilidade imediata para atender as necessidades de sensoriamento remoto de produtores e cientistas, tal como os veículos aéreos não tripulados (Swain et al., 2010).

Em vista disso, os VANT's oferecem maior flexibilidade para a coleta de imagens da área de cultura agrícola, o que é essencial para a AP (Moriya, 2015) uma vez que, além de possibilitar uma maior capacidade de diferenciação e comparação de elementos de uma cultura – satélite trazem resolução em metros –, garante um retorno visual de informações mais rápido de grandes áreas de plantio, auxiliando em uma rápida tomada de decisões por parte do agricultor (Abdullahi et al., 2015).

No entanto, também existem problemas inerentes ao uso desse tipo de sistema. Por serem leves, em sua maioria, podem apresentar baixa estabilidade e perda de capacidade de manobras em situações de turbulência e ventos fortes, por exemplo, resultando em diferenças em resolução ou angulação entre imagens sequenciais, além da distorção geométricas associadas ao voo em baixas altitudes (Lelong et al., 2008; Hardin e Hardin, 2010).

Além disso, as baixas altitudes também geram a necessidade de um maior volume de captura de imagens para que o sensoriamento remoto utilizando um VANT possam cobrir toda uma área de interesse. E, embora cause aumento no volume de dados, a sobreposição de imagens faz-se necessária como forma de se evitar o borramento de imagens (Aber et al., 2010).

Tem-se ainda, por consequência do grande volume de imagens capturadas, a necessidade da criação de mosaicos, visto que grandes áreas de coleta inviabilizam correções manuais de distorções geométricas, devido a demanda de tempo de processamento (Hardin et. al., 2010).

2.1.2 Processamento e mosaicamento de imagens de VANT's

O sensoriamento remoto tem como característica a aquisição de informações sem que haja contato direto com a superfície de interesse (Shiratsuchi et al., 2014) o que, na AP, refere-se a cultura plantada, o solo, e outros elementos associados ao plantio. Câmeras fotográficas são bons exemplos desse tipo de sensores.

Existem diferentes sensores fotográficos que podem ser utilizados em VANT's para a aquisição de dados imagéticos. Tais sensores são capazes de capturar diferentes bandas do espectro do infravermelho ao ultravioleta.

Tratando de câmeras que trabalham no espectro visível, as imagens obtidas podem ser processadas com o objetivo de detecção de falhas graves de plantio tais como falhas na linha de plantio de cana-de-açúcar (Jorge e Inamasu, 2014).

As imagens adquiridas são posteriormente repassadas para a base de dados de um SIG para que possam ser agrupadas posteriormente e trabalhadas por um software na reconstrução dos campos, sendo necessário o repasse em conjunto de dados de GPS do VANT para cada imagem adquirida possibilitando a predefinição de pontos para georreferenciamento (Abdullahi et al. 2015).

Os dados imagéticos podem ser processados como um todo ou individualmente, sendo necessária a criação de ortofotos e mosaico de ortofotos previamente à extração e análise de características de interesse – nas ortofotos ou em seu mosaico.


A ortofoto digital representa uma imagem digital em projeção cartográfica (Andrade, 1989). Assim, uma ortofoto é uma fotografia que representa as feições nela contidas em suas verdadeiras posições ortográficas, sendo geometricamente equivalentes a um mapa de linhas e símbolos, podendo ser realizadas medidas de distância, ângulos, posições e áreas diretamente a partir dela (Silva Jr, 2004).

Pode-se então dizer que as ortofotos são fotos retificadas de suas distorções. Tais distorções podem ser causadas por alterações espaciais (turbulência, por exemplo) e radiométricas (variação no brilho e cor) geradas devido instabilidades durante o voo da aeronave utilizada na coleta de dados (Jorge e Inamasu, 2014).

Os mosaicos, por sua vez, são representações unificadas de um grande volume de imagens (Chon et al., 2010). Por serem produzidos a partir das ortofotos, são também conhecidos como ortofotomosaicos, ortomosaicos ou mesmo, como já citado, mosaico de ortofotos.

Um mosaico possui todos os dados de georrefenciamento que as ortofotos agregavam, constituindo uma imagem completa de uma área de interesse, trazendo entendimento da visualização de todas as regiões de cultura numa plantação e possibilitando a tomada de decisões. A partir dos mosaicos aéreos agrícolas, uma checagem direcionada da plantação pode ser realizada afim de retornar informações diagnosticas precisas da área de cultivo (Leboeuf, 2000).

Figura 2. Exemplo de mosaico criado a partir de ortofotos.



Fonte: <http://aerorobot.mercadoshops.com.br/vant-aeronave-automatica-para-aerofotogrametria-23xJM>, acesso em jul. 2019.

Cada imagem e mosaico transportado à um SIG pode ser processada de diferentes maneiras para a extração de características de interesse (qualidade do solo, pragas na vegetação, linhas e falhas de plantio, por exemplo) e, posteriormente, correlacionados com outros mapas e informações. Nessa etapa, algoritmos relacionados à Visão Computacional são utilizados para a busca e compreensão dessas características. O uso de VANT's também pode agregar na correlação temporal das informações por serem capazes de atualizar o banco de dados de um SIG com mais frequência.

2.2 Visão Computacional

A Visão Computacional objetiva a tomada de decisões, a partir de imagens captadas por algum sensor, sobre algum objeto real e cenas baseadas em imagens. (Shapiro e Stockman, 2000). Deseja-se, assim, dotar um sistema computacional da capacidade de enxergar – através de imagens adquiridas – uma dada situação-problema e de, também, solucionar tal problema – tratar a imagem e extrair uma informação.

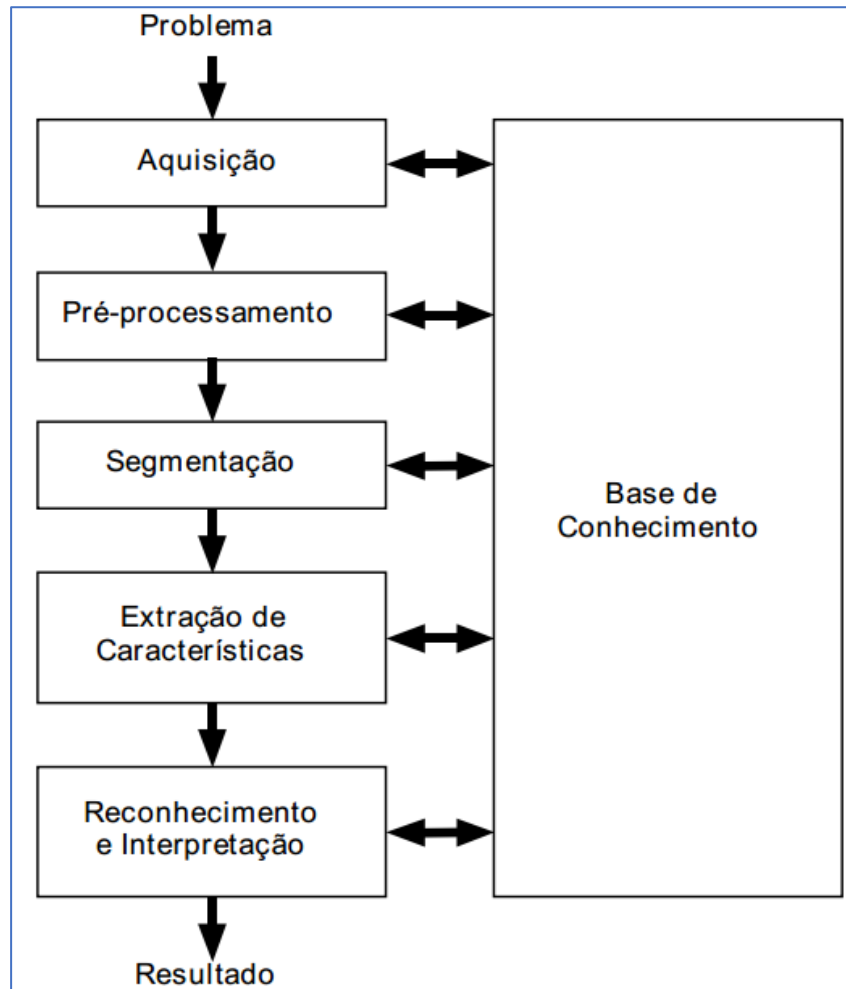
Como mostrado na agricultura de precisão, o sensoriamento de imagens tem diversas aplicações. O uso em outras áreas como no reconhecimento facial, no tratamento de imagens médicas (ressonância magnética, raio-x, dentre outras) e em direção de carros autônomos são também bastante explorados.

Imagens digitais são constituídas pelos *picture elements* (ou elementos de imagem, em tradução livre), mais conhecidos como pixels. Essas pequenas estruturas guardam um valor quantificado, normalmente na faixa de 0 a 255, que representam o brilho de cada ponto na imagem, sendo os valores menores os de menor intensidade e os maiores, de maior intensidade de brilho, ou vice-versa (Shapiro e Stockman, 2000).

Além disso, imagens digitais podem ser definidas como funções bidimensionais de valores finitos e discretos (Gonzales e Woods, 2010) onde os pixels formam uma matriz representando largura versus altura da imagem.

Ao tratarmos de uma atividade em visão computacional, incluímos em nosso estudo a forma de aquisição dos dados de imagem, seu processamento inicial e o entendimento analítico dos dados trazendo o seu significado visual de interesse. A Fig. 3 apresenta as etapas a serem seguidas por um sistema de visão computacional.

Figura 3. Etapas de um sistema de visão computacional.



Fonte: Marques Filho e Vieira Neto (1999)

2.2.1 Processamento Digital de Imagens

O processamento digital de uma imagem inicia-se com a produção de uma versão modificada da mesma, ou seja, após a transformação dessa imagem a mesma pode ser analisada em um formato no qual possa ser trabalhado: quantidade, texto ou decisão (Shih, 2009).

Com relação a Fig. 3, o processamento digital consiste das etapas de pré-processamento, segmentação e extração.

Ao capturar uma imagem, a mesma pode conter dados indesejáveis chamados de ruído (Klette, 2014). Ruídos podem ser causados por alterações de iluminação, desajuste focal, dentre outros problemas que podem ocorrer durante a aquisição e cabe à etapa de pré-processamento o aprimoramento da qualidade da imagem para as próximas fases (Masques Filho e Vieira Neto, 1999).

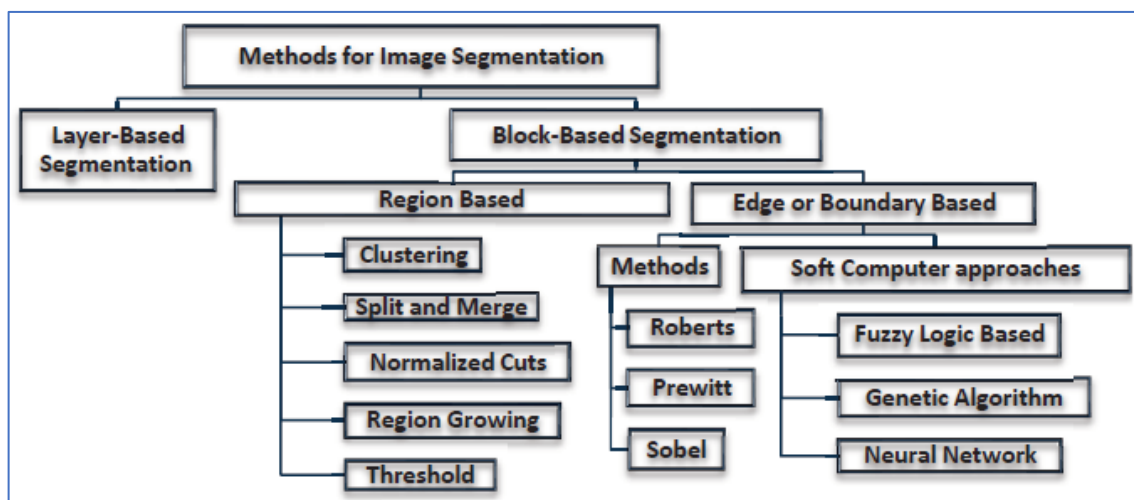
A segmentação consiste da divisão de uma imagem em regiões significativas e tem por objetivo a decomposição de uma imagem em partes, para que possa ser analisada posteriormente, e uma mudança da sua representação (Shapiro e Stockman, 2000) para que, em seguida, possam ser extraídas as características desejadas.

Os métodos de segmentação de imagem podem ser divididos em dois grandes grupos: baseada em camadas (*layer-based*) e baseado em blocos (*block-based*). Métodos baseados em camadas dividem a imagem em camadas retangulares buscando a separação de objetos e a criação de uma máscara para a reconstrução da imagem para o posterior compreensão e extração de características (Maheswari e Radha, 2011).

Os métodos baseados em blocos usam de base diversos elementos da imagem, como cores para elaboração de histogramas ou pixels para detecção de contorno, por exemplo, e podem ser divididos em três grupos: baseado em regiões, baseado em contornos ou limites, e híbridos (Zaitoun e Musbah, 2015).

A Fig. 4 mostra a distribuição de métodos relativos à segmentação com foco na segmentação baseada em blocos, voltada para a delimitação de elementos da imagem estruturada em seus elementos básicos, como o pixel.

Figura 4. Métodos de segmentação de imagem.



Fonte: Zaitoun e Musbah (2015).

Métodos híbridos podem ser utilizados para otimizar o processamento da segmentação além de poder ser associado a outras técnicas para diminuição da complexidade das imagens, sem que haja perda de seus dados, de modo a tornar o procedimento mais rápido ainda em sua execução.

Na sequência, serão apresentados os métodos de segmentação relevantes ao trabalho e o motivo de sua escolha. Além disso, outras técnicas utilizadas para a sequência do processamento serão apresentadas.

2.2.2 Limiarização

A limiarização (*thresholding*, em inglês) consiste da divisão da imagem em duas regiões classificadas por: objeto e plano de fundo (Masques Filho e Vieira Neto, 1999). Pela limiarização também é possível definir mais de um limiar, separando a imagem em três ou mais regiões de interesse (Gonzalez e Woods, 2010).

É um dos métodos de segmentação mais populares, sendo possível encontrar diversas abordagens para sua aplicação. Uma das abordagens mais conhecidas é o método de Otsu (Otsu, 1979) que visa a maximização da variância entre classes (*between-class variance*) baseando-se no histograma produzido pela imagem encontrando, assim, o limiar ótimo de modo automatizado.


Os histogramas apresentam a distribuição de pixels de uma imagem em relação a cada nível em sua escala de cinza (Masques Filho e Vieira Neto, 1999). Com isso, é possível identificar de maneira prática e satisfatória o melhor limiar em uma imagem até certo ponto, diminuindo a sua precisão conforme aumentam a proximidade entre picos e vales do gráfico e sua quantidade.

Assim, uma imagem $f(x,y)$ em escala de cinza, é transformada numa imagem $g(x,y)$, denominada imagem limiarizada. Essa nova imagem, com um limiar T , quando segmentada em dois níveis, pode ser definida por:

$$g(x,y) \begin{cases} = 1 & \text{para } f(x,y) \geq T \\ = 0 & \text{para } f(x,y) < T \end{cases} \quad (1)$$

Devido a produção de uma imagem final binária, a limiarização em dois níveis também é conhecida como binarização.

Figura 5. Limiarização em dois níveis. Da esquerda para direita temos: imagem original, histograma da imagem e limiar selecionado (em vermelho), imagem limiarizada.



Fonte: https://scikit-image.org/docs/dev/auto_examples/segmentation/plot_thresholding.html, acesso em jul. 2019.

Considerando a binarização de Otsu, seja L os níveis de cinza de uma imagem, $L = \{0, 1, \dots, L-1\}$, e $P(i)$ a razão do número de pixels em determinada intensidade i com relação ao total de pixels da imagem, temos que:

$$\sum_{i=0}^{L-1} P(i) = 1 \quad (2)$$

Supondo um limiar T , separando a imagem em $C1$ e $C2$, nos intervalos respectivos $[0, T]$ e $[T, L-1]$, as classes sem tem sua probabilidade cumulativa dada por:

$$w_1 = \sum_{i=0}^T P(i) \quad (3)$$

$$w_2 = \sum_{i=T+1}^{L-1} P(i) = 1 - w_1 \quad (4)$$

E a intensidade média dos pixels por classe:

$$\mu_1 = \sum_{i=0}^T \frac{i \times P(i)}{w_1} \quad (5)$$

$$\mu_2 = \sum_{i=T+1}^{L-1} \frac{i \times P(i)}{w_2} \quad (6)$$

Assim, a intensidade média global e a variância entre classes (a ser maximizada) é dada por:

$$\mu_G = \sum_{i=0}^{L-1} i \times P(i) \quad (7)$$

$$\sigma_B^2 = w_1 w_2 (\mu_1 - \mu_2)^2 \quad (8)$$

Diversas outras abordagens podem ser citadas as quais utilizam uma dada função cuja sua otimização auxilia na determinação automatizada de um limiar. As funções de Pun (1981) e de Kapur (1985) são duas abordagens baseadas na maximização da entropia de uma imagem para medir a homogeneidade entre as classes limiarizadas. Klitter e Illingworth (1986) e Lloyd (1985) utilizaram uma abordagem de erro mínimo, buscando a minimização da taxa de erro de classificação dos pixels por meio da avaliação da variância de funções gaussianas de densidade.

Embora interessantes, todos esses métodos são computacionalmente complexos e exponencialmente custosos quando estendidos para uma abordagem de multilimiarização (Yin, 1999). Faz-se necessário o uso de abordagens que possam otimizar esses métodos tornando-os factíveis num sistema de limiarização multinível real.

Uma forma de realizar isso é através de métodos estocásticos de procura, ao invés do método iterativo utilizado pelas abordagens para binarização. Uma abordagem de busca que seja confiável de encontrar um valor otimizado, mesmo que não exato, acelera o processo e o torna viável para uma maior gama de aplicações. Assim, o uso de funções de limiarização associadas a Algoritmos Genéticos foi uma das formas encontradas por autores como Yin (1999) e Hammouche (2005) para solucionar a questão.

Nos dois trabalhos, temos uma aplicação eficiente da limiarização multinível onde o uso da função de Otsu traz os resultados mais eficientes quando comparados a outros métodos conhecidos e melhor se adapta a distinções menos evidentes entre os objetos de interesse e o plano de fundo ao analisar o histograma.

2.2.3 Algoritmos Genéticos

Os Algoritmos Genéticos (AG's) são algoritmos de busca estocásticos inspirados na Teoria de Darwin sobre a evolução sendo utilizados para problemas de otimização e de busca a partir da elaboração de um algoritmo que aplica conceitos de operadores evolutivos tais como: seleção, cruzamento, mutação e elitismo (Bhandarkar and Hui Zhang, 1999).

Tipicamente, um AG possui as seguintes etapas (Mitchell, 1999):

1. Geração de uma população de cromossomos/indivíduos (cada um representa uma solução ao problema);
2. Cálculo da aptidão de cada cromossomo;
3. Repetição das seguintes etapas até que seja atingido o número desejado de descendentes:
 - a. Seleção de um par de cromossomos da atual população (pais). Durante a seleção, a técnica utilizada pode fazer com que um mesmo cromossomo seja selecionado mais de uma vez.
 - b. Recombinação dos pais selecionados à uma taxa de cruzamento predeterminada. Caso haja cruzamento faz-se a seleção aleatória de pontos de troca de genes (bits de constituem um cromossomo). Caso não ocorra, os descendentes serão uma cópia exata dos pais.
 - c. Mutação dos descendentes à uma taxa de mutação predeterminada e remanejamento dos cromossomos para uma nova população.
4. Alterar a população atual com a nova população criada.
5. Retornar ao passo 2.

As técnicas utilizadas para representar cada um dos passos são diversas e devem ser escolhidas de acordo com o problema. As abordagens utilizadas no presente trabalho serão apresentadas nos tópicos seguintes.

Além disso, o processo de um AG, como o descrito, será repetido até que seja encontrada uma condição de parada. Normalmente, essa condição está atrelada a um valor de aptidão a ser atingido ou a uma quantidade limite de gerações estipulada. Cada iteração da sequência de passos apresentada é denominada em AG como uma geração.

Cromossomos

Em AG, o cromossomo representa um candidato à solução de um dado problema, sendo usualmente codificado como uma *string* de bits e podendo cada bit – gene do cromossomo – assumir o valor 0 ou 1 (Mitchell, 1999), quando representados como um vetor binária.

Figura 6. Representação de cromossomo como string binária.



Cromossomos podem ser codificados de diversas maneiras e a escolha da representação estará relacionada a qualidade de resolução do problema. Isso ocorre, pois, escolhida a representação, a forma como os operadores genéticos são utilizados é diretamente influenciada (Rodrigues, 2004).

Operador de seleção

O operador de seleção tem por função selecionar cromossomos da população para a reprodução/cruzamento e isso ocorre de modo que os cromossomos mais aptos tendem a serem escolhidos mais vezes (Mitchell, 1999). Alguns dos métodos utilizados para seleção são: método proporcional, ranking e torneio.

Na seleção pelo método proporcional, também denominado de método da roleta, os indivíduos têm sua probabilidade de seleção atrelada à sua aptidão de modo que, quanto mais apto for o indivíduo maior suas chances de seleção (Linden, 2008), podendo um mesmo indivíduo ser selecionado mais de uma vez.

Esse método possui dois grandes problemas: redução da eficiência de seleção, devido ao fato de que os melhores indivíduos terão um maior número de cópias com o passar das gerações; e a criação de super indivíduo, o qual, devido a sua elevada aptidão, será selecionado facilmente durante a roleta e causará uma convergência prematura do AG (Tomassini, 1995). Uma forma de suavizar esses problemas é com a aplicação de abordagem que não sejam baseadas puramente num julgamento pela aptidão (Tomassini, 1995), como o método do torneio.

Na seleção por torneio, um número n de indivíduos é selecionado aleatoriamente e com a mesma probabilidade de escolha, sendo o vencedor do torneio aquele que possuir maior aptidão (Tomassini, 1995). A seleção dos cromossomos também pode ser dada pela seleção de um número aleatório r onde, sendo esse número um valor entre 0 e 1, o vencedor será aquele com maior aptidão, caso r seja menor que um valor de parâmetro k , ou, em caso contrário, o com menor aptidão entre os participantes do torneio (Mitchell, 1999).

O torneio ocorre quantas vezes forem necessárias até que sejam selecionados um número total de indivíduos igual ao total da população. Além disso, vale ressaltar que, a cada seleção realizada, os participantes voltam a integrar a população inicial podendo ser escolhidos novamente no torneio seguinte.

A seleção por torneiro será utilizada no presente trabalho, tanto pelo fato de atenuar os dois problemas supracitados quanto por ser um método eficiente para esse passo. Em conjunto a ele, será utilizado a técnica denominada elitismo.

O elitismo é um modo eficiente de melhoramento da performance de um GA através do armazenamento de um número pré-estabelecido dos cromossomos mais aptos de cada geração (Mitchell, 1999). A técnica impede que os cromossomos mais aptos de uma geração sejam perdidos por não serem selecionados para o cruzamento ou por serem modificados por esse operador ou pelo operador de mutação.

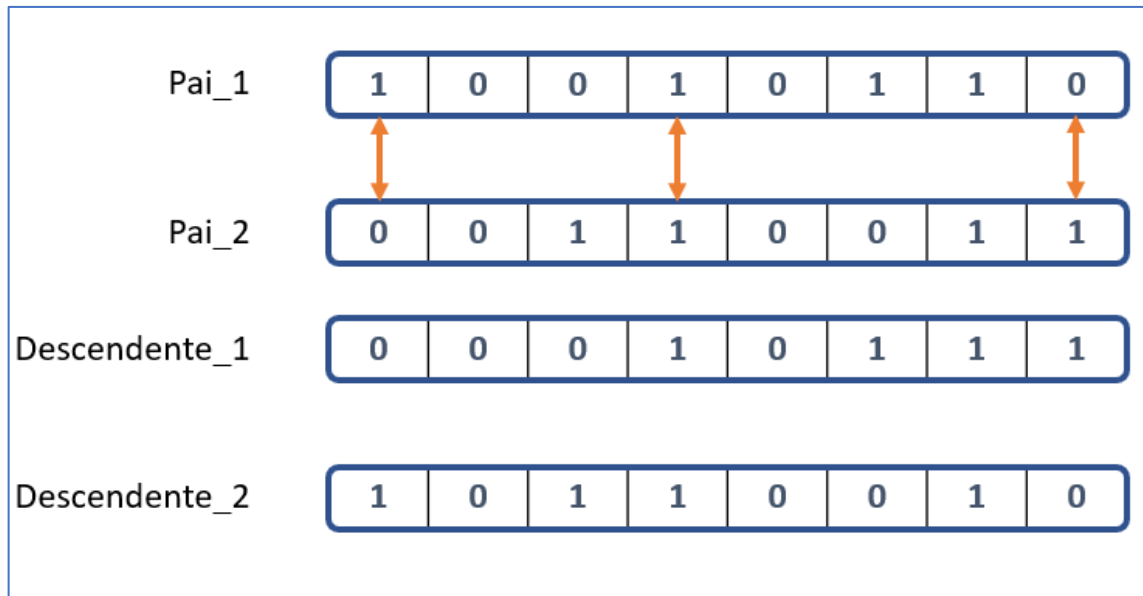
Operador de cruzamento

O cruzamento utiliza pares de cromossomos, os quais foram escolhidos previamente a partir de um método de seleção. Ao selecionar uma abordagem de cruzamento, estes cromossomos, denominados cromossomos pais, trocam seus genes entre si produzindo dois novos indivíduos, denominados descendentes.

A escolha de abordagem depende bastante das particularidades de cada AG (Mitchell, 1999). Assim sendo, uma abordagem de cruzamento proporcional modificada será aplicada ao presente trabalho atendendo suas configurações (apresentadas na sessão 3.4).

No cruzamento proporcional, um número aleatório é gerado para cada *locus* – ou seja, para cada posição do gene no cromossomo – e, caso esse valor esteja dentro da chamada taxa de cruzamento, os genes dos pais serão trocados. Ao final, após percorrer todas as posições, os pais recombinados formam agora um novo par de descendentes que farão parte da nova população para a próxima geração após passarem pelo operador de mutação.

Figura 7. Cruzamento proporcional. As setas vermelhas indicam os pontos onde o cruzamento ocorreu devido ao número aleatório ter se encaixado na taxa de cruzamento.




Operador de mutação

A mutação possui uma taxa probabilística de ocorrência bem menor que a do cruzamento e auxilia na variabilidade, dificultado que a população fique presa numa região fechada de soluções. Para esse operador, caso um número aleatório seja sorteado e caia dentro da taxa de mutação o gene terá seu valor modificado.

Uma abordagem interessante, a qual será utilizada no trabalho, é a mutação por permutação (swap). Nela, quando ocorre a mutação, o gene troca de posição com outro do vetor cromossômico, fazendo com que seus valores sejam preservados, porém, noutra ordem.

Figura 8. Ocorrência de mutação swap em cromossomo.



A técnica, no contexto do trabalho, permite a preservação do número de limiares da imagem o que é importante para que, durante a busca do indivíduo mais apto haja um padrão do cálculo de aptidão com relação ao número de níveis de limiarização de todos os candidatos.

Aptidão

Até o momento, citou-se que um AG busca pelos indivíduos mais aptos, afim de gerar uma solução representada pelo melhor cromossomo de uma população ao final de todo o processo do algoritmo, ou seja, ao atingir uma condição de parada. Assim, a decisão de se um indivíduo é mais apto por outro é feita a partir do cálculo de uma função de avaliação.

A função de avaliação é o modo utilizado para medir a qualidade de cada indivíduo como uma solução de um dado problema, além de ser a única relação entre o AG e o problema real (Linden, 2008). Isso se dá pelo fato de ser durante a avaliação em que o cromossomo será decodificado para realização dos cálculos e posteriormente codificado novamente para seguir o fluxo do AG torando-o, assim, mais genérico e de fácil reutilização, bastando-se modificar a função de avaliação para cada problema.

2.2.4 Transformada Discreta de Wavelet

Um modo de acelerar o processamento de uma imagem é a partir da redução de sua complexidade. Em técnicas de limiarização que se baseiam no histograma em escala de cinza de uma imagem, a diminuição de complexidade pode ser obtida por uma construção em escala reduzida do histograma, acarretando em um menor do número de níveis de cinza para serem investigadas. Essa redução pode ser obtida por meio de um método de Transformada de Wavelet.

A Transformada de Wavelet é uma ferramenta eficiente para lidar com aproximação (fusão) de dados, sua compressão e, também, a remoção de ruídos (Guijarro et al., 2015; Chang et al., 2000; Walker, 1999; Goswami e Chan, 1999). Além disso, pode ser utilizado para diminuir o gasto de tempo computacional durante uma segmentação utilizando um método híbrido como a limiarização auxiliada por um AG (Hammouche, 2008; Pereira et al., 2014).

Similar à Transformada de Fourier, ambas têm como base para a análise de dados a decomposição prévia do sinal original de interesse. Porém, as Transformadas de Fourier são melhor aplicadas às frequências estacionárias, sendo as Transformadas de Wavelet, mais adaptadas para trabalhar com dados acústicos e visuais (Daubechies, 1990).

Tal transformada decompõe um sinal em diversos outros mais simples em diferentes escalas sendo a redução da dimensão do sinal proporcional ao aumento de nível da transformada (Kim et al., 2013). Quando tratamos de sua aplicação em processamento digital, os parâmetros da

transformada são discretizados sendo amostrado em uma sequência diádica $2^r, r \in \mathbb{Z}$ para classes de wavelet específicas de modo que isso não afete as propriedades da transformada (Olivio, 1994).

Essa, agora denominada, Transformada Discreta de Wavelet (TDW) decompõe o histograma original em dois sinais em seu próximo nível de redução: o sinal de aproximação e o sinal detalhado (Hammouche, 2008). Nesse nível mais baixo, a versão reduzida do histograma será expressa pelo sinal de aproximação, o qual contém as características gerais do histograma original.

A TDW em um nível de redução r , executada com o operador 2^n , após o convolução com um histograma $h(i)$ é dada por (Kim, 2003):

$$h^r(j) = WT^r[h(i)], r \in \mathbb{Z} = h_A^r(j) + h_W^r(j) \quad (9)$$

Onde $h_W^r(j)$ representa o sinal detalhado e $h_A^r(j)$ o sinal de aproximação no nível r .

A soma dos sinais decompostos recompõe o histograma original com seus L níveis de cinza onde, para cada nível de redução, temos que o histograma reduzido tem um tamanho $L^r = L/2^r$.

Normalmente, na conversão de uma imagem em seu espaço original (RGB, por exemplo) para escala de cinza, utilizam-se um total de 256 níveis de cinza. Assim, numa primeira convolução de uma wavelet com o histograma, o sinal de aproximação possuirá 128 níveis de cinza e, ao reduzirmos esse sinal para $r+1$, teremos uma nova decomposição em sinal detalhado e de aproximação tendo esse último, 64 níveis de cinza. Na nova dimensão, teremos (Kim, 2003):

$$h_A^r(j) = h_A^{r+1}(j) + h_W^{r+1}(j) \quad (10)$$

Para aplicações voltadas para a agricultura, a família de wavelets de Daubechies é a mais adequada quando comparada a outras famílias de funções (Bossu et al., 2009; Chou et al., 2007). Mais precisamente, a função ‘db1’ da família Daubechies é, simultaneamente, simples e eficiente para detecção de características (Bay et al., 2008), como a detecção de linhas de plantio para vegetação verde, sendo ideal para a convolução com sinais de entrada como o histograma de uma imagem.

2.2.5 Morfologia Matemática


Em Visão Computacional, a morfologia matemática é uma ferramenta que visa a representação e descrição de forma de objetos a partir da extração de características (Shih, 2009) como formas e texturas. Essa extração é realizada a partir de elementos estruturantes os quais, normalmente, tem poucos pixels de dimensão e atuam como sondas das imagens binárias (Shapiro e Stockman, 2000) produzidas pela etapa de segmentação, passando pelos elementos positivos dessas imagens.

A translação pela imagem binária por parte diferentes elementos estruturantes podem aumentar ou diminuir regiões de interesse, moldando-as para melhor extrair a informação de interesse.

Elemento estruturante

Os elementos estruturantes são imagens binárias que representam uma forma específica de interesse. Embora possam ser representados de diferentes formas e tamanhos, existem algumas formas mais comumente utilizadas, tais como retângulos ou regiões circulares de dimensões específicas (Shapiro e Stockman, 2000).

Figura 9. Exemplos de elementos estruturantes. Da esquerda para direita temos: cruz, quadrilátero 3x3, linha de comprimento 7, diamante 7x7. Os pontos pretos representam a origem.



Fonte: Gonzalez e Woods (2010).

A origem de um elemento estruturante costuma estar atrelada ao pixel central quando este é simétrico, porém, pode ser referenciado em qualquer outro pixel (Shapiro e Stockman, 2000).

Principais operações em morfologia matemática

As operações morfológicas básicas são denominadas: dilatação, erosão, fechamento e abertura. Nessas operações, a origem do elemento estruturante irá transladar sobre todos os bits de valor 1 de uma imagem binária.

Na operação de dilatação, toda a região do elemento estrutural passa por uma operação do tipo OR com a imagem binária o ser encontrado nessa imagem um pixel de valor 1 (Shapiro e Stockman, 2000). Assim, após percorrer todos os pixels de 1-bit, ou seja, após percorrer todo o objeto, as regiões ao redor desse objeto também terão pixels de 1-bit seguindo a forma do elemento estruturante, expandindo sua forma.

A operação de erosão ocorre de maneira opositiva à dilatação. Enquanto na dilatação temos uma operação do tipo OR, na erosão temos uma função AND (Shih, 2009).

Sendo assim, quando a origem do elemento estrutural passa por um pixel de 1-bit do objeto e não encontra uma correspondência exata com os pixels ao seu redor, todos os pixels da região tornam-se 0-bit, causando uma redução desse objeto.


Dessas operações elementares da morfologia matemática, surgem o fechamento e a abertura.

O fechamento tem por objetivo preencher concavidades e buracos que sejam menores que o elemento estruturante além de remover pixels 0-bit desconexos (Shih, 2009).

Já a abertura irá remover os pixels de uma região que seja menor que o elemento estruturante, eliminando protuberâncias, desfazendo conexões estreitas entre regiões e suavizando pixels 1-bit desconexos (Shih, 2009).

No fechamento, uma operação de dilatação é realizada e seguida por uma operação de erosão enquanto, na abertura, as operações são realizadas na ordem contrária (Shapiro e Stockman, 2000).

Figura 10. Operações morfológicas: a) representa uma imagem binária; b) um elemento estruturante; c) é o resultado da dilatação da imagem pelo elemento; d) é o resultado da erosão; e) resultado do fechamento; f) resultado da abertura.



Fonte: adaptado de Shapiro e Stockman (2000).


Esqueletização

A esqueletização é um procedimento similar ao denominado afinamento, porém, focado em manter a característica estrutural principal do objeto.

O esqueleto de uma imagem é estabelecido pela representação do objeto por uma linha de 1 pixel de espessura, localizada no centro desse objeto e preservando sua forma topológica (Shih, 2009). Sendo assim, a forma remanescente preserva a conectividade e extensão do objeto, mas elimina grande parte de seus pixels o que, por sua vez, poupa memória e agiliza o processamento analítico do padrão da imagem.

As noções acerca do esqueleto de uma imagem são um resultado da chamada Transformada de Eixo Medial (Blum, 1967) e pode ser definido como sendo um conjunto de centros de circunferências que tocam os limites do objeto em dois ou mais pontos (Gonzales e Woods, 2001).

Figura 11. Processo para esqueletização de uma figura retangular.



Fonte: <http://www.inf.u-szeged.hu/~palagyi/skel/skel.html>

2.2.6 Transformada de Hough

A Transformada de Hough (Hough, 1968) é um método utilizado para a detecção de segmento de retas e arcos de círculos em imagens binárias.

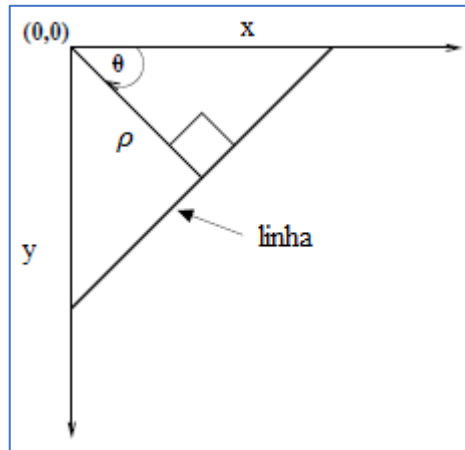
A Transformada de Hough (TH) faz uso de uma matriz de contagem para examinar cada pixel de uma imagem e sua vizinhança (os pixels ao seu redor do pixel principal). Sendo uma linha dada por $\rho = x * \cos\theta + y * \sin\theta$ (Duda e Hart, 1971), a matriz de contagem possui duas dimensões e é formada pelo par (ρ, θ) , onde ρ é a distância perpendicular da origem do plano à reta imaginária que cruza o ponto/pixel analisado, e θ , o ângulo formado pela linha perpendicular ao eixo horizontal (no sentido anti-horário).

Em uma imagem, cuja origem fica no canto superior esquerdo, a equação é dada como sendo:

$$\rho = x * \cos\theta - y * \sin\theta \quad (11)$$

Conforme pode ser observado pela Fig. 12.


Figura 12. Parâmetros ρ e θ da equação $\rho = x \cos \theta - y \sin \theta$.



O problema passa de uma situação de detecção de linhas no espaço da imagem, para a detecção de pontos no espaço de Hough, onde uma quantidade mínima estipulada de votos em um determinado ponto indica a existência de uma determinada linha no espaço original.

Para cada pixel não-nulo, uma análise do elemento e seus vizinhos é feita baseando-se numa reta imaginária que passa por esse ponto, variando seu ângulo de inclinação. Uma contagem dos pares (ρ, θ) que passam pela reta – ou seja, a contagem dos pixels não-nulos que passar pela reta – é realizada e esses valores são salvos na matriz de contagem. Assim, os pontos que representam picos de ocorrências na matriz são os mais prováveis de representarem uma linha na imagem (Shapiro e Stockman, 2000).

Figura 13. Espaço cartesiano e espaço de Hough. Uma reta no plano da imagem, correspondo a um ponto no plano de Hough.



Fonte: <https://nabinsharma.wordpress.com/2012/12/26/linear-hough-transform-using-python/>, acesso em: jul.

2019.

O uso da TH tem sido amplamente explorado ao longo das décadas e, para a minimização de recursos utilizados na computação das linhas, existem implementações probabilísticas do método que buscam atender essa necessidade mantendo a qualidade do resultado.

Uma abordagem de interesse para o trabalho é a desenvolvida por Matas e Klitter (2000), denominada Transformada de Hough Probabilística Progressiva (THPP), cujo o objetivo é o de minimizar a proporção de pontos votados de modo a manter os índices de falso negativo e falso positivo em níveis próximos ao da TH padrão.

Ainda segundo os autores, a proposta do THPP é a de minimizar o custo computacional explorando a quantidade de votos necessários para que uma linha possa ser detectada através de um controle dinâmico de um limiar para aceitação para que se tenha confiabilidade na determinação da linha. Além disso, o algoritmo é adequado para aplicações em tempo real por intercalar a votação e a detecção de linhas, importante para sistemas em tempo real com taxa fixa de tempo para tarefas.

2.3 Mobile Cloud Computing

Mobile Cloud Computing (MCC) refere-se a uma infraestrutura na qual o armazenamento e o processamento de dados são transferidos de um dispositivo móvel para plataformas computacionais centralizadas localizadas na nuvem, as quais possuem maior potencial para realizar essas tarefas (Raja et al., 2018).

O seu paradigma trata da combinação entre *mobile computing* e *cloud computing*, unindo suas partes benéficas de modo a possibilitar a entrega de serviços móveis que foram executados utilizando o potencial de centrais de dados, dando aos dispositivos móveis a capacidade de computações mais complexa mesmo possuindo recursos limitados para tanto (Noor et al., 2018).

A *mobile computing* em si trata da capacidade do uso de recursos computacionais por dispositivos móveis sendo esses capazes de executar tarefas semelhantes às de desktops (Noor et al., 2018). Assim, *mobile computing* é uma plataforma voltada para a administração de informações utilizada e acessível independente de sua localização e sem limitações de tempo para acesso (Asrani, 2013).

A plataforma tem seu ambiente caracterizado pela mobilidade e capacidade de acesso em diferentes tipos de rede (wireless e 4G LTE, por exemplo), porém, também pela frequente desconexão de rede e baixa confiança e segurança (Noor et al., 2018).

Já a *cloud computing* busca uma centralização do armazenamento e processamento de dados como forma de ampliar as capacidades de redes pautadas em Tecnologia da Informação (Mell e Grance, 2011). Caracteriza-se por um serviço solicitado sob demanda, amplo acesso à rede por diferentes dispositivos, agrupamento de recursos como: armazenamento, capacidade de processamento, banda de rede e memória, rápida elasticidade para alocação de recursos conforme necessidade, monitoramento e elaboração de relatórios em tempo real para manutenção da transparência entre provedor e usuário dos serviços em nuvem (Noor et al., 2018).

Serviços em nuvem são classificados em modelos, sendo divididos em (Kumas et al., 2014):

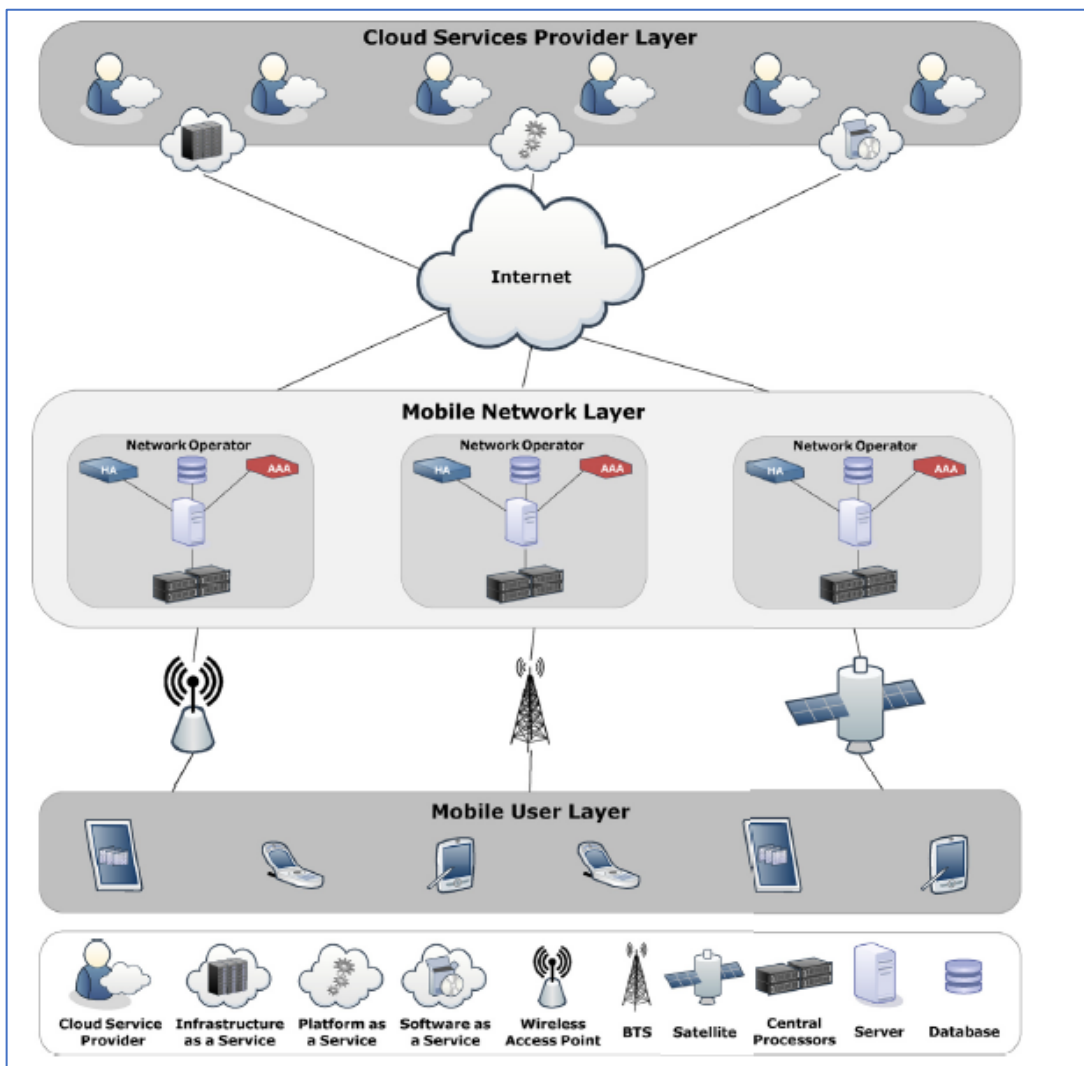
- **Infraestrutura como um Serviço (IaaS):** dá acesso aos usuários para processamento, rede, armazenamento e outros recursos básicos, podendo ser a infraestrutura expandida ou diminuída dinamicamente baseado na necessidade do cliente. Como exemplos de IaaS, temos: Amazon EC2 (*Elastic Cloud Computing*) e S3 (*Simple Storage Service*).
- **Plataforma como um Serviço (PaaS):** oferece um ambiente integrado avançado para desenvolvimento e teste de aplicações customizadas. Exemplos desse serviço são: Google App Engine, Microsoft Azure e Amazon Map Reduce/S3.
- **Software como um Serviço (SaaS):** provê aplicações e acesso a informações remotamente pela internet e tem como exemplo o Microsoft's Live Mech, que também permite o compartilhamento de arquivos e pastas em múltiplos dispositivos.

Da junção dessas características, temos a MCC trata da complementação em performance dos dispositivos móveis através de serviços de bancos de dados em servidores, aplicativos, conexão web e outras melhorias trazidas pela arquitetura orientada a serviços da computação em nuvem. Ao tratarmos do processamento de imagens, por exemplo, temos a necessidade de que um dispositivo seja capaz de armazenar e processar esses dados. Quando o dispositivo é conectado à um serviço em nuvem, imagens capturadas podem ser imediatamente armazenadas nela e utilizar de todo seu potencial para um processamento rápido, devolvendo os resultados ao usuário.

A arquitetura de MCC é dividida em camadas, sendo elas descritas por (Noor et al., 2018):

- **Usuários Móveis:** a camada é formada pelos usuários de um serviço em nuvem através de seus dispositivos que se conectam, a partir de uma rede móvel, à Camada de Rede Móvel.
- **Rede Móvel:** nessa camada as requisições dos usuários móveis são organizadas por múltiplos operadores de rede e as informações, entregues a partir de uma estação. Os serviços solicitados, passados procedimentos de segurança, podem ser acessados na nuvem.
- **Provedores de Serviços em nuvem:** consiste dos vários provedores de serviços em *cloud computing* cujos serviços providos incluem IaaS, PaaS e SaaS. Estão inclusos serviços acessíveis por dispositivos móveis via internet, possuindo elasticidade baseada na demanda do usuário.

Figura 14. Arquitetura de MCC.

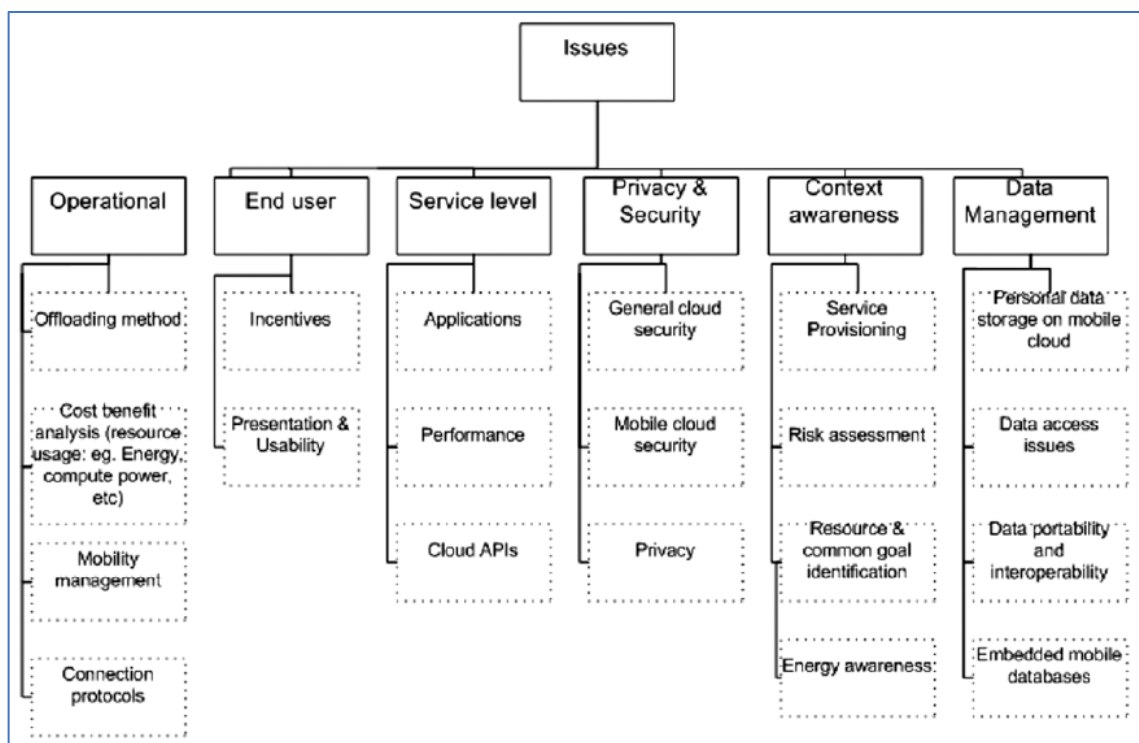


Fonte: Noor et al. (2018).

Para que os usuários de dispositivos móveis possam aproveitar das vantagens da nuvem, é necessário observar os aspectos relacionadas ao problema no qual ele será aplicado e as suas necessidades, com relação ao que possa afetar os recursos de seu dispositivo, além de conectividade, gasto de bateria etc.

Abordagens de MCC podem ser relacionadas aos problemas em torno de sua implementação. A Fig. 15, apresenta os diferentes aspectos focados e seus subtópicos num formato taxonômico:

Figura 15. Taxonomia dos problemas relativos a MCC.



Fonte: Fernando et al. (2013).

Da abordagem escolhida em vista das necessidades do sistema, o uso de MCC traz como vantagens (Kumar et al., 2014):

- **Maior sobrevida de bateria:** reduzir a necessidade de processamento e administração de armazenamento, dentre outras atividades no dispositivo móvel, auxiliam na economia de bateria e diminui a necessidade de gastos em busca de um dispositivo mais robusto para realizar tarefas complexas.
- **Melhoramento no armazenamento de dados e capacidade de processamento:** acesso, armazenamento e processamento são realizados em nuvem.

- **Maior confiabilidade:** dados e aplicativos são armazenados e possuem back-up em diversos computadores espalhados pelo mundo, reduzindo a chance de perdas dos mesmos.
- **Suprimentos dinâmicos:** alocação dinâmicas de recursos de acordo com a necessidade do usuário móvel
- **Multi-locação:** aplicações diversas podem ser fornecidas a um grande número de usuários a partir da divisão de recursos e custos por parte dos provedores de serviço (provedores de rede, donos de centrais de dados, etc.).
- **Facilidade de integração:** serviços de diferentes provedores podem ser facilmente integrados em nuvem para suprir as demandas dos usuários.

3 METODOLOGIA

Nessa sessão serão mostradas as aplicações dos conceitos apresentados no capítulo anterior, que visam solucionar o problema da detecção das linhas de plantio e suas falhas dentro da proposta objetivada.

Na figura a seguir, é apresentado um fluxograma do funcionamento básico do algoritmo de detecção.

Figura 16. Fluxograma do funcionamento básico do algoritmo de detecção de linhas e falhas de plantio(continua)

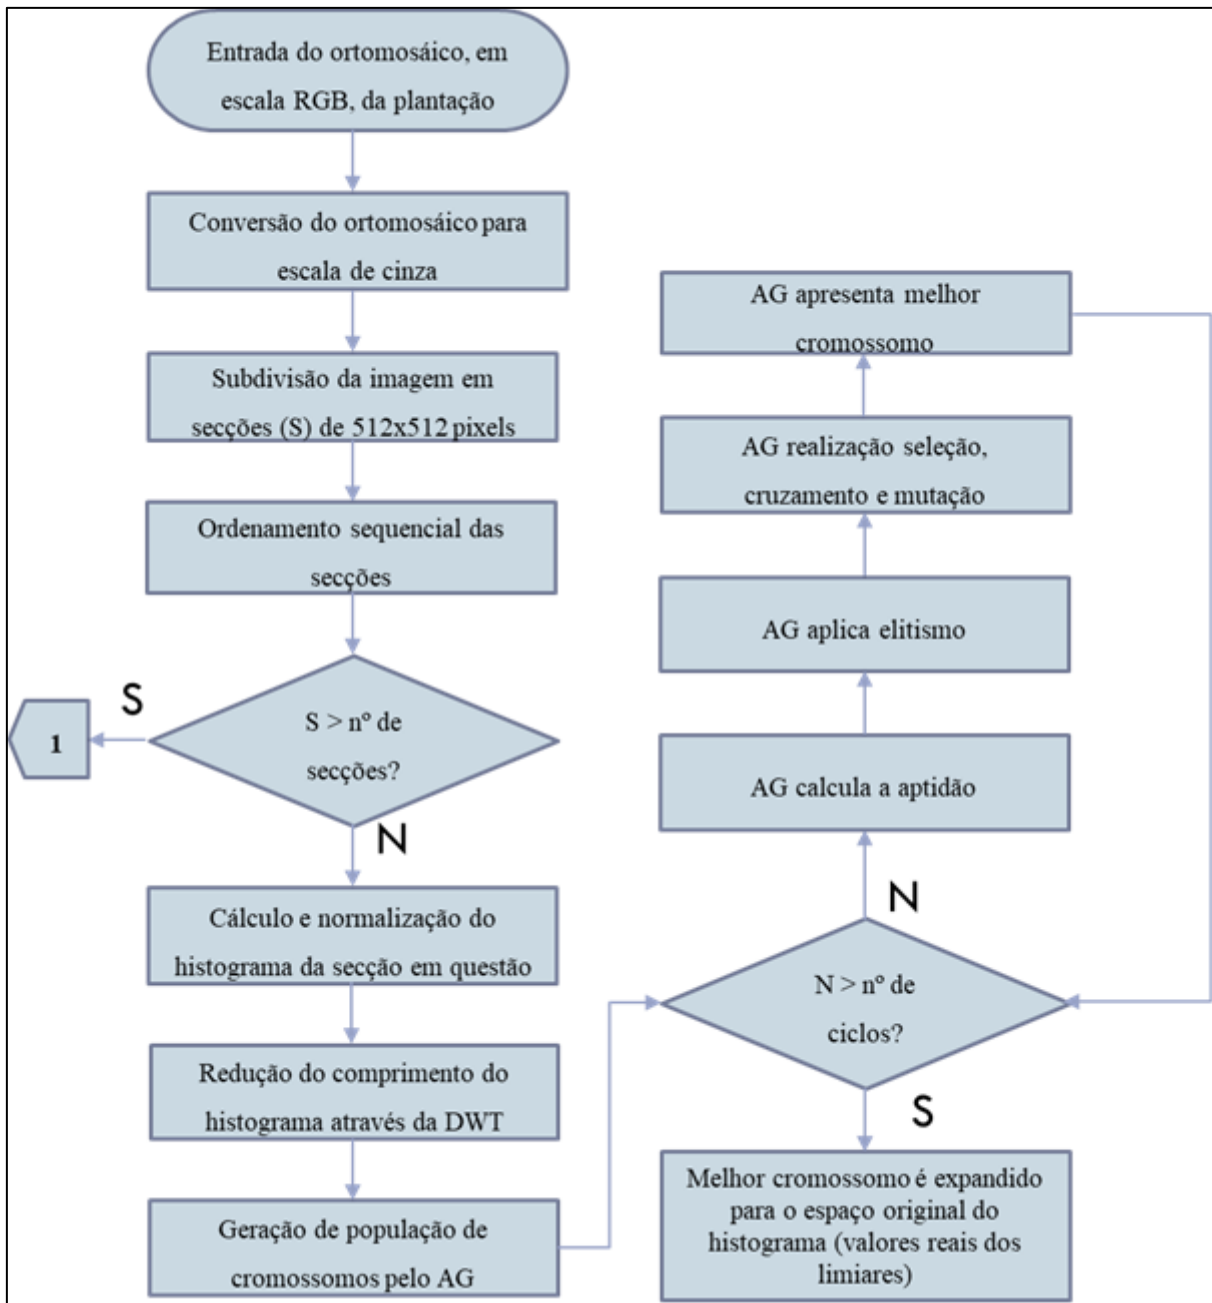
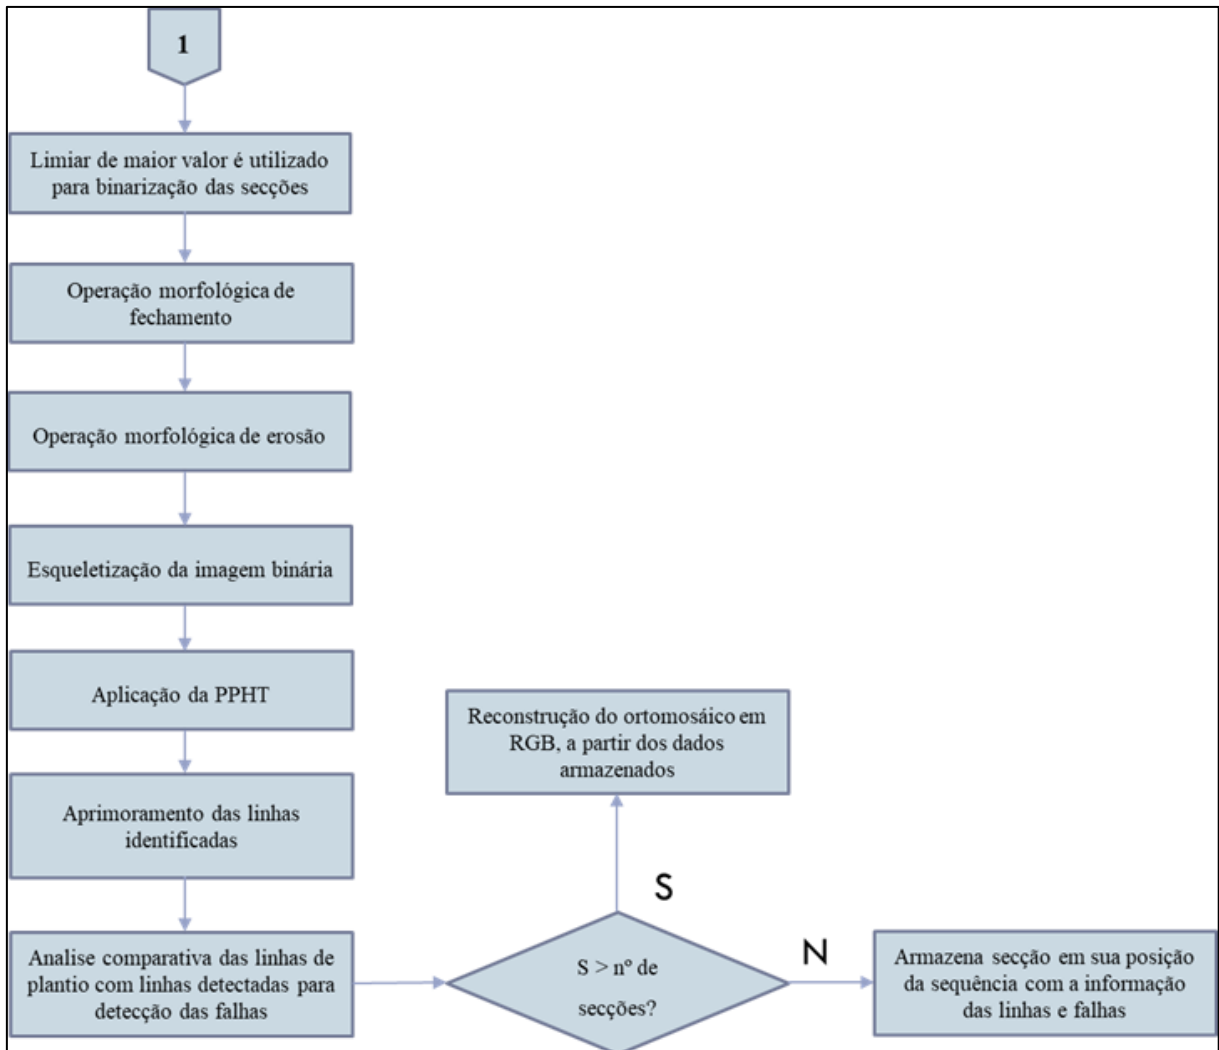


Figura 17.(continuação) Fluxograma do funcionamento básico do algoritmo de detecção de linhas e falhas de plantio.



3.1.1 Ortomosaico e sua fragmentação

As imagens de plantações utilizadas no projeto são de propriedade da empresa Sensix (<https://sensix.com.br/>) e foram capturadas utilizando uma câmera RGB embarcada em um VANT.

Uma das etapas essenciais ao projeto é o desmembramento do ortomosaico em porções menores.

Por depender do terreno de plantio, a configuração das linhas de plantação nem sempre se fazem em linhas retas e, sendo assim, a divisão do ortomosaico gerado permite que as faixas de plantio em cada secção possam ser consideradas como linhas retas. Isso é necessário para que


seja aplicada uma Transformada de Hough que simplificará a determinação das linhas de plantio, conforme será apresentado mais adiante.

Figura 18. Recorte do ortomosáico em escala 1:500. As linhas de plantio são curvilíneas em maior ou menor grau, dependendo da área geográfica da porção da plantação.



Fonte: base de dados de amostras da Sensix.

Figura 19. Exemplo da fragmentação do ortomosáico em secções de igual tamanho.



Fonte: adaptação de imagem da base de dados de amostras da Sensix

Tal seccionamento é feito separando o ortomosáico em imagens de 256×256 pixels, e cada imagem é analisada individualmente pelo algoritmo de detecção de linhas e falhas de plantio.

Finalizado esse processo de análise, as imagens são novamente conectadas reconstruindo o ortomosáico, mas agora com as informações sobre as falhas nas linhas de plantio.

Como a tratativa dos processos será dada em cada secção previamente, trataremos daqui em diante do que será executado em cada uma delas, quando não especificado diferentemente.

3.2 Segmentação de imagem: limiarização e multilimiarização

Dado o seccionamento da imagem, prosseguimos os procedimentos para segmentação da imagem.

Num primeiro momento, para que a segmentação ocorra de maneira ágil, os segmentos do ortomosáico são passados da *escala RGB* para a *escala de cinza*.

Já em escala de cinza, será realizada uma multilimiarização da imagem de modo a separar, de forma mais evidente, o que é a vegetação, solo e outros elementos que possam atrapalhar na identificação da vegetação como, por exemplo, sombras.

A aplicação de multilimiarização com quatro (4) limiares é suficiente para realização dessa atividade, dada a natureza de preparação inicial dada às imagens produzidas pela Sensix. Porém, como é de interesse que seja realizada uma detecção ágil das linhas de plantio, a transformação em escala de cinza não é suficiente.

Tendo isso em mente, adentramos à aplicação da Transformada Discreta de Wavelet, que irá nos prover uma redução do espaço original de aplicação da multilimiarização em escala de cinza.

3.3 Transformada Discreta de Wavelet

Após a transformação da imagem para a escala de cinza, são feitas três (3) convoluções consecutivas utilizando a TDW, tendo como wavelet aplicada a função Daubechies 1 (db1).

Para a mudança do espaço RGB para escala de cinza, o novo espaço conta com uma escala completa, ou seja: 256 diferentes níveis de cinza. Assim, em relação as convoluções aplicadas, temos que $r=3$ e $L^3 = \frac{256}{2^3}$.

Dada a redução de escala, utilizamos o sinal de aproximação para dar sequência ao tratamento das imagens no qual, conforme calculado, L^3 constitui um espaço com 32 níveis de cinza. O histograma original e o reduzido (sinal de aproximação) são exemplificados nas figuras abaixo:

Figura 20. Exemplo de histograma utilizando 256 níveis da escala de cinza e a distribuição de pixels ao longo dos níveis.

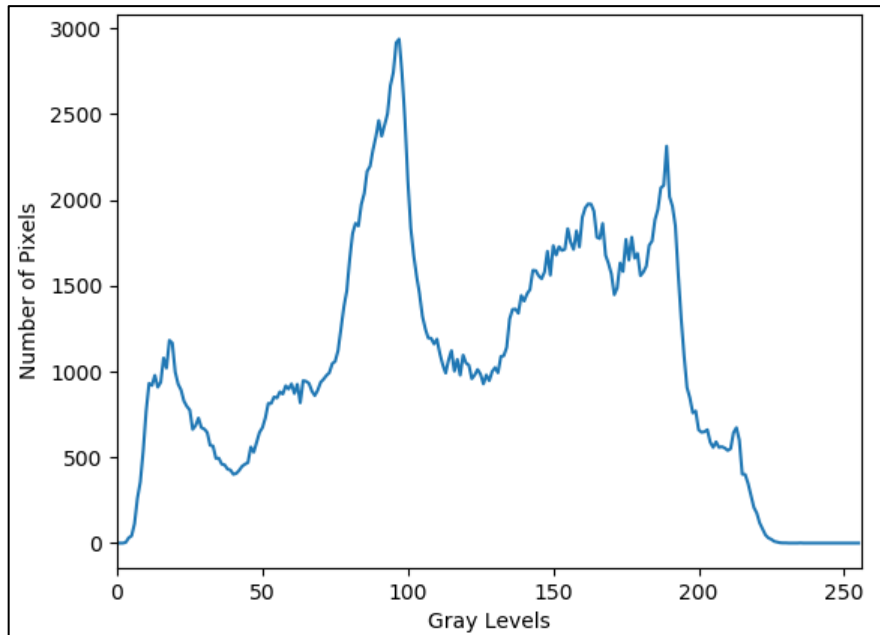
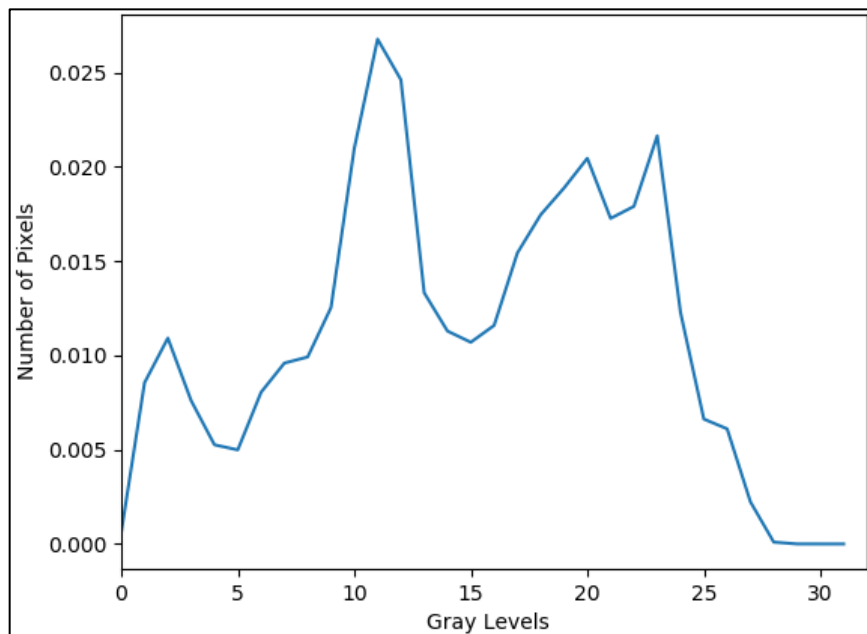


Figura 21. Histograma reduzido após três convoluções ($r=3$).



Com a redução da busca de limiares entre 256 para 32 possibilidades, ganha-se em agilidade para a convergência do AG de multilimiarização além de, pelas propriedades de restauração da TDW do espaço reduzido ao original, uma alta acurácia quando comparado à aplicação do algoritmo direto à escala original do histograma.

Prosseguindo com o pré-processamento da imagem, será aplicado o AG para localizar os limiares de cada secção.

3.4 Algoritmo genético para multilimiarização

Utilizando o sinal de aproximação gerado, será aplicado o AG para multilimiarização de modo a localizar 4 pontos do histograma em escala reduzida que representem os limiares essenciais para o posterior tratamento de localização das linhas de plantio.

População e critério de parada


O tamanho da população a ser gerada aleatoriamente é dependente do número de reduções realizadas no histograma. Assim, a partir de testes realizados, uma boa abordagem pode ser dada pela equação:

$$P = \frac{100 \times r}{2^r}, \text{ para } r \geq 1 \quad (12)$$

Desse modo, o AG conta com uma população P de 38 indivíduos. Os indivíduos, também denominados *cromossomos*, tem uma composição binária de 32 posições (genes), onde os genes de valor 1 representam os limiares e, em cada cromossomo, temos sempre 4 limiares.

A condição de parada estabelecida foi por número de geração, N, sendo ele igual à 100.

Figura 22. Representação do cromossomo, suas posições e seus limiares.



Seleção

O *torneio* foi utilizado como método de seleção dos cromossomos, sendo a mesma feita aos pares com taxa de vitória de 70%, ou seja, caso um valor decimal aleatório entre 0 e 1 seja lançado e se enquadre na taxa de vitória, escolhe-se o cromossomo com melhor aptidão. Cromossomos são postos em pares e selecionados até que atinjam a quantidade de P sendo eles, então, encaminhados para a etapa de cruzamento.

Cruzamento

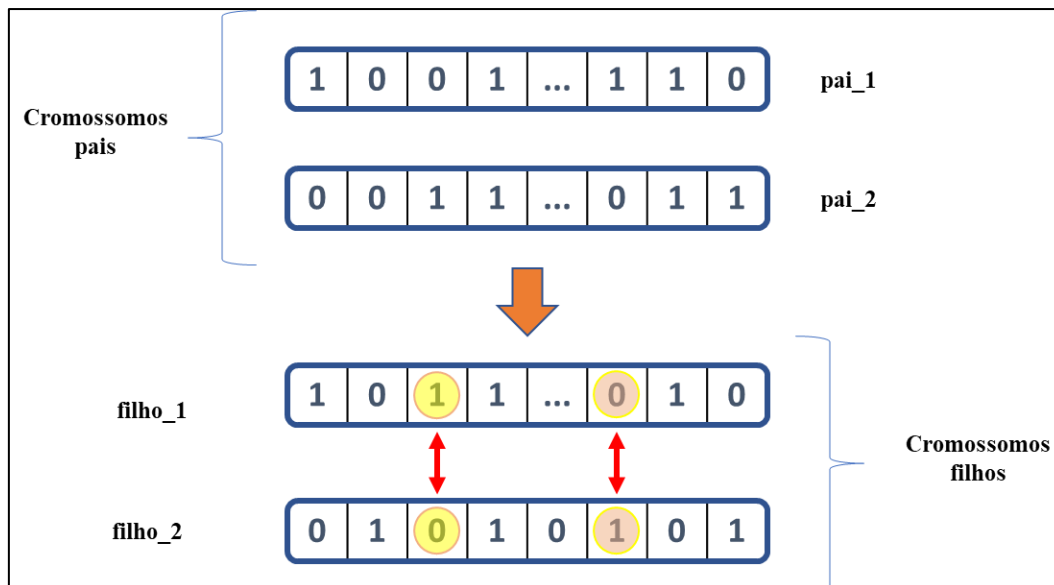
O método do cruzamento proporcional foi o escolhido com a adição de um elemento condicional para que a integridade dos cromossomos fosse preservada.

A integridade referida diz respeito ao número de limiares fixo de cada cromossomo. Para o caso da atual aplicação, a quantidade de limiares, ou seja, a quantidade de elementos 1-bit no cromossomo foi definida e deve sempre ser igual a 4.

A taxa utilizada foi de 70% e, na ocorrência de cruzamento, devemos analisar os valores que estão sendo modificados entre os indivíduos. Assim, caso um indivíduo tenha seu número de limiares aumentado, consequentemente, teremos que o outro indivíduo terá seus limiares diminuído.

Para combater essa ocorrência, ao ser identificada essa modificação no número de limiares numa dada posição, o algoritmo será encarregado de selecionar aleatoriamente uma outra posição de genes que possam balancear a quantidade de limiares novamente e de imediato. A figura abaixo exemplifica uma situação do tipo:

Figura 23. Representação da operação de cruzamento.




Mutação

Para a mutação, o método utilizado foi o swap, de modo a garantir a integridade do cromossomo, tal como no cruzamento.

As mutações ocorrem com taxa de 5% e, na sua ocorrência, busca-se a troca entre posições com valor de binário diferente.

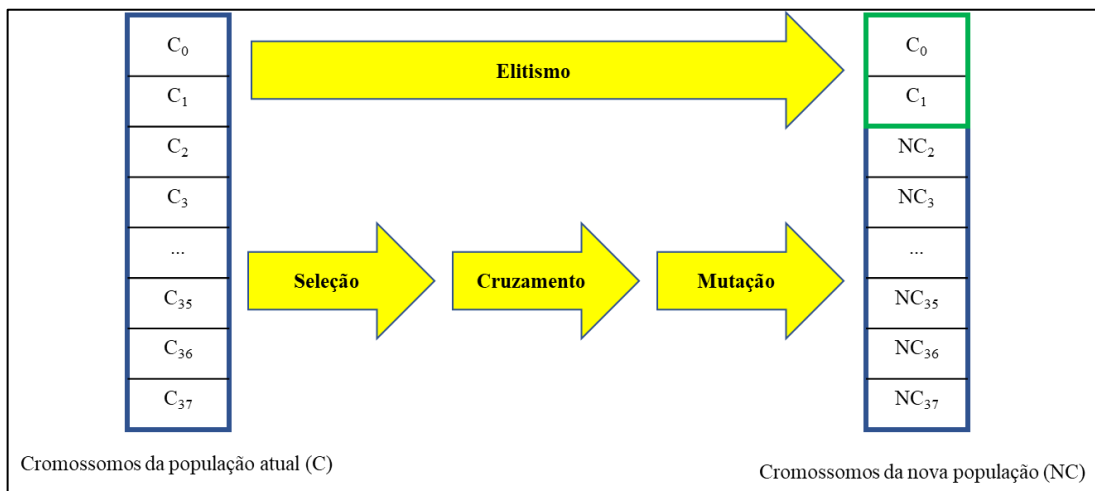
Figura 24. Representação da operação de mutação.



Elitismo

O elitismo preservará 5% dos indivíduos mais aptos para a próxima geração a ser executada de modo a substituir os piores indivíduos da geração executada. Isso auxilia o AG na manutenção de bons candidatos, auxiliando na convergência do algoritmo.

Figura 25. Representação do elitismo de 5% em população de 40 indivíduos. Melhores indivíduos da atual geração são enviados diretamente para a próxima.



Função de Aptidão

O cálculo da aptidão foi baseado na função de Otsu, a qual, com a maximização da variância entre classes, fornecerá os indivíduos mais aptos.

As equações [2 – 8] trataram da divisão do histograma para um único limiar. Levando-as em consideração e expandindo-as para o caso de multilimiar, a variância entre classes pode ser expressa na forma (Merzban and Elbayoumi, 2018):

$$\sigma_b^2(t) = \sum_{k=0}^K w_k \times (\mu_k - \mu_T)^2 \quad (13)$$

Onde K representa os $t + 1$ grupos e $k \in \{0, 1, \dots, K\}$.

Para um grupo C_k , a média μ_k é expressa em termos da probabilidade de ocorrência de um nível de cinza i , $P(i)$, e sua probabilidade cumulativa w_k :

$$\mu_k = \sum_{i \in C_k} \frac{i \times P(i)}{w_k} \quad (14)$$

Onde:

$$w_k = \sum_{i \in C_k} P(i) \quad (15)$$

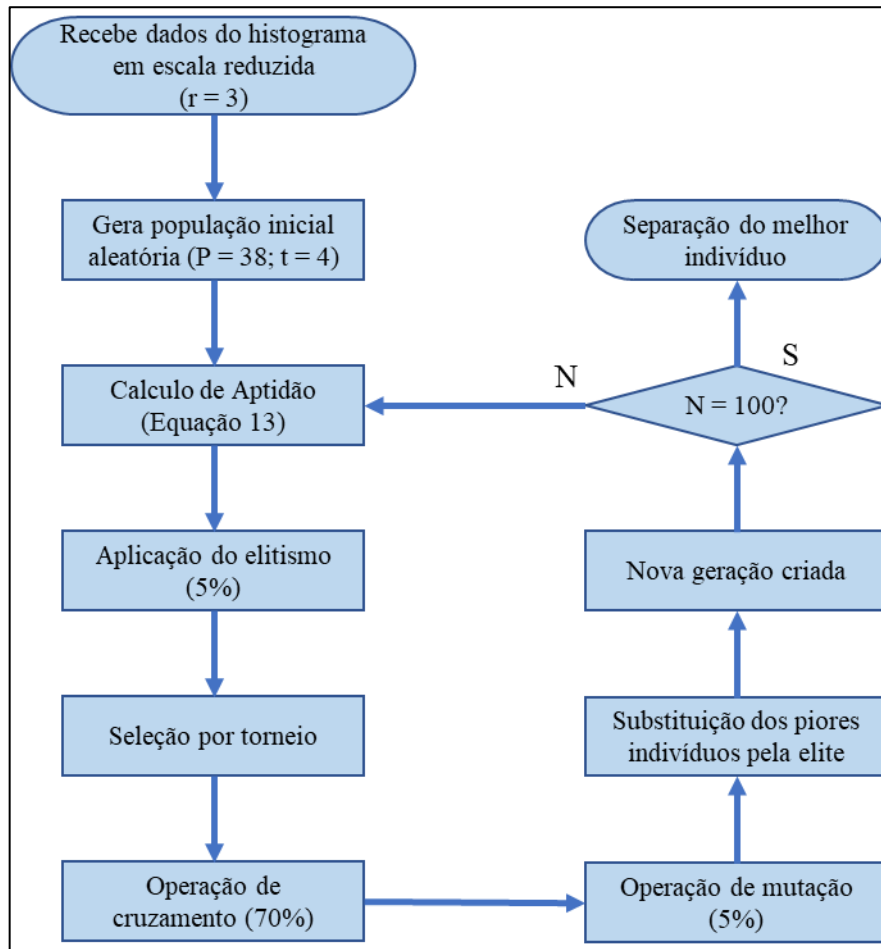
A média total da imagem é dada por:

$$\mu_T = \sum_{i=0}^{L-1} i \times P(i) \quad (16)$$

Sequência do Algoritmo Genético

Dadas as características essenciais do AG desenvolvido, temos que o seu processo ocorre conforme mostrado abaixo.

Figura 26. Fluxograma com ciclo do Algoritmo Genético ao receber histograma reduzido de uma secção.



Expansão dos limiares ótimos

O melhor indivíduo selecionado ao final do algoritmo corresponde ao histograma cujos limiares forneceram a maior variância entre classes.

Porém, para que a imagem possa ser trabalhada, devemos agora expandir os limiares encontrados no histograma reduzido de modo que expressem seus valores no espaço original (histograma com os 256 níveis de cinza).

Para que seja realizada a expansão dos limiares para o espaço original, cada limiar t_i deve ser multiplicado por um fator 2^r , tal que (Kim et al., 2003):

$$t_i = t_i^r \times 2^r, \text{ para } i = 1, 2, \dots, k \text{ e } t_i \in [0, L-1] \quad (17)$$

Com os valores t_i podemos realizar uma multilimiarização da imagem, além de extrair dados relevantes dependendo de sua aplicação

3.5 Os limiares e o processo morfológico de esqueletização

Ao tratarmos do pré-processamento inicial utilizando o AG desenvolvido, foi apresentado na sessão 3.3 que quatro limiares eram suficientes dadas as características das imagens. De fato, os 4 limiares proporcionam para esse caso a possibilidade de distinção entre: sombras, solo, vegetação e demais elementos.

Para a etapa de esqueletização é necessária uma representação binária da imagem a ser tratada, porém, uma simples binarização direta da imagem imputaria em distorções dentre os elementos que desejamos distinguir: vegetações e demais elementos. Isso ocorre, pois as imagens reais de uma plantação não têm uma distinção tão evidente dos pixels que possibilite separar facilmente cada um dos elementos, sendo a função de Otsu puramente aplicada uma boa alternativa apenas nesses casos.

Desse modo, o AG para multilimiarização objetivou a separação dos aspectos da plantação para que fosse possível uma esqueletização mais precisa. Com isso, um dos limiares será utilizado como ponto de binarização da imagem atingindo, assim, a distinção desejada entre vegetação e demais elementos.

Posteriormente à multilimiarização, o limiar de maior valor faz a separação do grupo que representa a vegetação e será utilizada para a binarização da imagem em escala de cinza no seu espaço original – com 256 níveis.

Partiremos agora para a execução de operações morfológicas para refinar a imagem binarizada previamente a sua esqueletização de modo a otimizar o resultado.

Primeiramente, para remover pequenos espaços vazios que podem ser gerados durante a segmentação, mas que não representam falhas de plantio, é feita uma operação de fechamento. A operação utiliza o elemento estruturante do tipo *disco* (elipse) com dimensão de 3x3.

Em seguida, uma operação pura de erosão é realizada utilizando um elemento estruturante do tipo diamante com dimensão de 3x3. Essa segunda operação morfológica tem por intuito reduzir alguns ruídos da imagem, que seriam pixels próximos as regiões de linha de plantio, de modo a deixar tais linhas com uma forma mais regular e, além disso, reduz o caminho de pixels preparando a imagem para a esqueletização.

Por fim, temos a operação final de esqueletização em si, dando aos elementos correspondentes a vegetação de plantio da imagem binarizada, seu formato de linha de 1-bit.

Com essa representação em linhas da plantação, podemos passar para a aplicação da THPP.

3.6 Transformada de Hough Probabilística Progressiva

Depois de todos os tratamentos de pré-processamento dado às secções do ortomosáico, temos o esqueleto da imagem pronto para que possa ser aplicado um método de Transformado de Hough: a THPP.

Para a aplicação, poder ser feita a definição de um tamanho mínimo que represente uma linha, de modo que seja necessário uma quantidade mínima de pontos votados que indique que a formação de um traço representaria uma porção da linha de plantio propriamente dita. Além disso devemos definir um espaçamento máximo entre linhas permitido de modo que entendamos que esse distanciamento represente ou não uma falha real no plantio ou se seria apenas uma pequena falha da composição do esqueleto durante sua formação.

Dadas essas duas informações, além da precisão de busca referente aos valores de ρ e θ , a serem pesquisados no plano cilíndrico (o passo utilizado), e do limiar de votos necessários para validar um ponto pertencente a uma linha, temos o necessário para a aplicação da Transformada de Hough Probabilística Progressiva.

Os passos utilizados foram: $\rho = 1$ pixel ; $\theta = \frac{\pi}{180} rad$; limiar de 2 votos e lacuna máxima entre linhas de 2 pixels. Lacunas maiores que essas não necessariamente representarão falhas de plantio ao final do processo, devendo ser feita ainda uma análise final do tamanho da lacuna baseado na teoria de falha de plantio em plantação de cana, podendo a informação adquirida representar apenas um espaçamento comum entre os elementos do plantio (que não deixam de ser importantes para algum outro tipo de análise da plantação).

3.7 Aprimoramento das linhas detectadas

Embora a THPP tenha um papel essencial na detecção das linhas de plantio, quando aplicada para a detecção da vegetação, acaba construindo retas não contínuas e um pouco difusas, apesar de representarem com certa precisão as regiões de plantio.

Isso se dá pelas características da própria transformada que, mesmo auxiliando na localização com velocidade e certa acurácia, não utiliza todos os pixels da imagem para a pesquisa das regiões de interesse. Porém, a mesma fornecesse os pontos necessários para que possa ser realizado um refinamento.

Como já falado em tópicos anteriores, as secções são de tamanhos tais que a identificação das linhas de plantio se aproxima de retas. Desse modo, podemos utilizar os dados da THPP

para refinar os pontos encontrados pela mesma e transformá-los em retas contínuas, conectando-as sobre a área de secção. Os dados da THPP não serão descartados finalizado o aprimoramento, sendo utilizados numa etapa mais adiante para a identificação das falhas de plantio.

Feito o cálculo para identificar a angulação média das retas produzidas, podemos saber qual a direção em que sua maioria se inclina e, com esse valor de inclinação, o algoritmo pode traçar retas nas regiões com maior quantidades de pontos que passam por elas.

3.8 Localizando as falhas de plantio

De posse dos dados da THPP e das linhas aprimoradas, é feita uma análise sob a secção em seu espaço binarizado.

Para cada linha de plantio é verificado se há ou não a identificação que presente a vegetação de cana naquela região que, numa imagem binária, seriam os elementos 1-bit. Essa verificação é feita comparando a região com a linha aprimorada produzida, através da sondagem da linha e de uma faixa próxima dela, semelhante ao realizado por um elemento estruturante.

Verificadas as regiões sem vegetação na linha de plantio, é então feita uma análise final para saber se aquele *gap* representa, de fato, uma falha no plantio. Para isso, a distância entre os colmos¹ ao longo de um sulco² deve ser maior que 0,5 metros (Stolf, 1986).

Temos, assim, a finalização da análise e processamento de uma secção, a qual é repetido para as demais de modo que, finalizadas, o ortomosáico possa ser reconstruído e uma visão da plantação como um todo possa ser verificada com as linhas de plantio, e o tamanho das falhas contidas em cada uma, identificadas.

3.9 Revisão: Fluxo do sistema

Em vista de tudo que foi apresentado até o momento temos que uma visão geral da aplicação desenvolvida pode ser resumida da seguinte forma:

¹ Colmo é a denominação dada a caules de vegetações como a de cana.

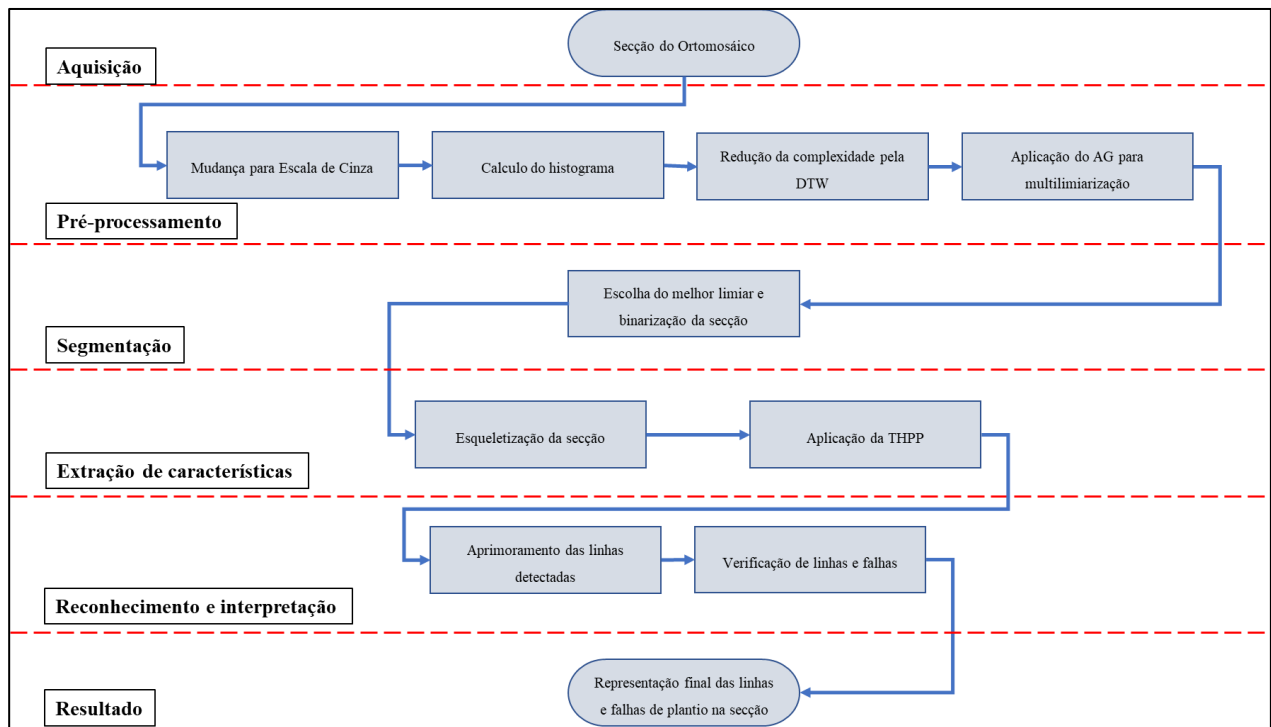
² Sulco é a região arada, ou seja, a linha de plantio.

Tabela 1. Método computacional proposto.

Fluxo do método computacional proposto
1. Recebimento da secção do ortomosáico
2. Mudança da escala RGB para de cinza
3. Cálculo do histograma
4. Redução da complexidade pela aplicação do TDW
5. Aplicação do AG para multilimiarização
6. Escolha do limiar para binarização da secção
7. Esqueletização da secção
8. Aplicação da THPP
9. Aprimoramento das linhas detectadas
10. Verificação de linhas e falhas
11. Representação final das linhas e falhas de plantio sob a secção em RGB.

Dessa sequência, também é possível estabelecer a relação com as divisões de um sistema em visão computacional, conforme apresentado na Fig. 3. Assim, temos o fluxo conforme figura abaixo:

Figura 27. Fluxo do método computacional proposto e sua correspondência com relação as etapas de um sistema em visão computacional.



3.10 Associação ao Mobile Cloud Computing

Além do desenvolvimento de um algoritmo aplicável na localização de falhas em linhas de plantio, é importante associar tecnologias de Agricultura de Precisão à sistemas que fazem uso de metodologias que possam auxiliar na rápida obtenção de resultados, acessível de qualquer lugar e que, com isso, agregue eficiência para a lavoura.

Como apresentado até o momento, o algoritmo desenvolvido é uma possível solução voltada a um problema em plantações de cana, tendo como foco não apenas processar as imagens de uma plantação com agilidade como, também, de manter boa acurácia através do método utilizado.

Entramos agora na necessidade de entrega desses resultados ao usuário final: o agricultor. E para isso, o uso de ferramentas em *Mobile Cloud Computing* tem um grande potencial.

No contexto da nossa sociedade dos últimos anos, *smartphones* estão cada vez mais presentes em meios corporativos, no gerenciamento de sistemas de informação, jogos, educação, saúde, dentre outros (Akherfi et al., 2016). Isso pode ser comprovado também por um estudo realizado pela *ABI Research (Allied Business Intelligence, Inc)*, a qual estimou, em 2015, que o uso de serviços em nuvem via *smartphones* atingiria mais de 240 milhões de negócios, elevando a receita em aplicações de MCC para 5,2 bilhões de dólares (Dinh, 2013).

O presente trabalho não adentra em um projeto integrado ao paradigma MCC, mas apresentar uma ideia que agregue nesse âmbito é relevante para a construção de futuros produtos na área, além de estudos mais aprofundados relacionados ao tema. O intuito nesse momento é a proposição da ideia de uma ferramenta que provê ao agricultor um modelo *IaaS* e *SaaS* para auxiliá-lo de forma simples, acessível em qualquer momento e escalonável.

Ortomosáico

Embora haja um crescente incremento em robustez dos dispositivos móveis, atividades como o reconhecimento de imagens e a tomada de decisões tem uma intensidade de processamento maior do que a suportava por esses aparelhos (Akherfi et al., 2016). Assim, o trato de imagens de plantações, por exemplo, não poderia ser concebido com uma resposta ágil em campo após sua coleta, pela necessidade de recursos não presentes no local.

Partindo da obtenção das imagens, o carregamento e processamento das mesmas por meio de um software para gerar o ortomosáico ganha agilidade ao ser direcionado para uma nuvem. Sua propriedade elástica permite a alocação de mais recursos, conforme necessidade, para que

o mapa em ortomosáico seja gerado e, além do ganho com tempo de processamento, temos também o armazenamento da imagem e dados num local seguro e acessível por meio de equipamentos móveis.

Desse modo, todos os dados de uma plantação podem ser concentrados num único local, com baixo risco de perdas de dados e guardando um histórico que pode ser tratado, futuramente, por ferramentas de *data mining* e *big data* para a extração de informações que venham a ser relevantes ao produtor rural. Assim, além de auxiliar na base do algoritmo de detecção de linhas e falhas de plantio, os dados poderão ser utilizados para outras finalidades do sistema de AP do agricultor.

Essa é, também, uma tendência observada em pesquisas. É estimado para 2020, pela *ABI Research*, que haja um incremento no mercado voltado para a computação em nuvem e *big data* dos valores já apresentados para 8,6 bilhões de dólares (abi reasearch 2016).

Uma boa abordagem seria o repasse das imagens, ao serem adquiridas pelos drones, diretamente para a nuvem. Isso pode possibilitar uma maior quantidade de memória disponível aos equipamentos de processamento associados ao VANT utilizado, deixando-o mais “à vontade” para a realização de atividades essenciais ao controle de voo e aquisição, excluindo as imagens já capturadas após receber um sinal de que seu upload na nuvem foi finalizado.

Processamento do ortomosáico

Quando todas as imagens da plantação estão num servidor em nuvem é possível, através do desenvolvimento de uma interface com usuário, a determinação do conjunto de dados que será utilizado para a produção do ortomosáico ou, caso seja de interesse, uma rotina pode ser criada interfaceada com o VANT utilizado na aquisição dos dados para que, verificado que a tiragem de fotos foi finalizada, tal processo de sintetização do ortomosáico já seja iniciado.

Seja qual for a forma escolhida, é importante que haja uma interface transparente ao usuário final que informe o estado de processamento dos dados, além de garantir acesso aos mesmos. Assim, finalizado o processamento e geração do ortomosáico, será possível que o usuário da interface com o servidor solicite, através de algum de seus dispositivos, que a análise das linhas de plantio seja feita para o mapa carregado.

Associada a robustez de um servidor em nuvem, temos a agilidade do algoritmo desenvolvido para a detecção de linhas e falhas de plantio. Com a computação em nuvem, todos os processos do sistema de visão computacional podem ser realizados e o resultado acessado a qualquer momento e em qualquer localidade, bastando acessar o servidor através de um portal

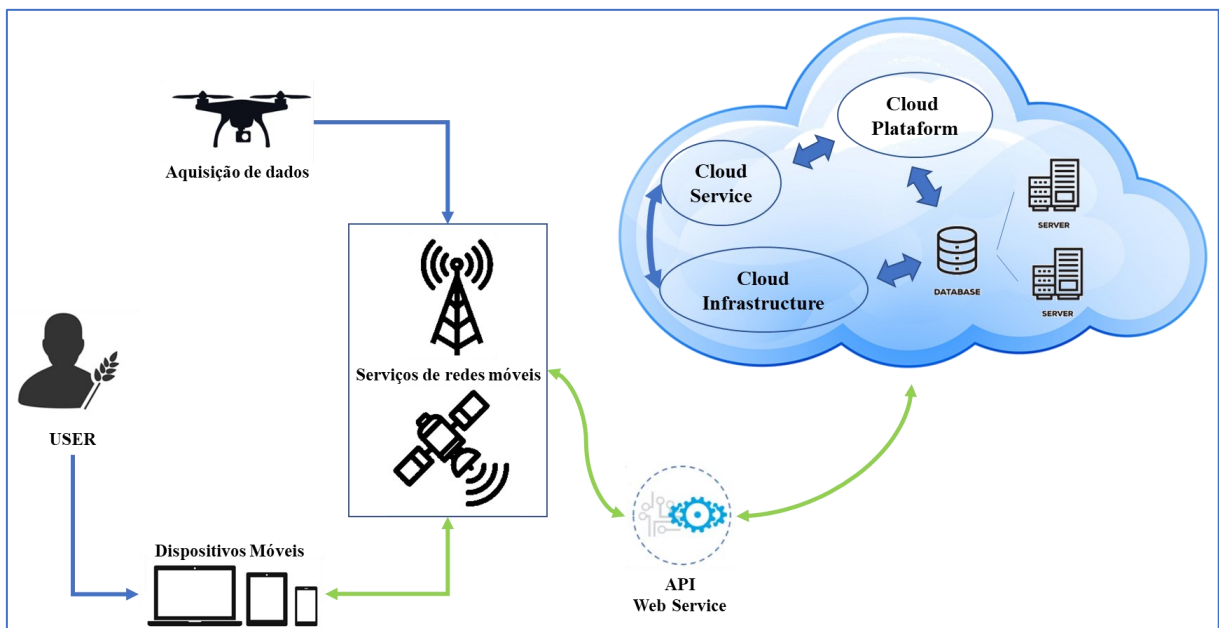
ou aplicativo, por exemplo. Além disso a computação de dados feita externamente aos dispositivos móveis reduz o consumo de sua bateria em 33% e aumenta o tempo de resposta em 45% (Shiraz et al., 2014).

Com uma interface que pode ser acessada através de redes moveis, para a produção de resultados e relatórios e a segurança de um sistema em nuvem, soluções em AP tendem a ser chamativas ao produtor por trazer praticidade e lucro, quando bem adequada e administrada para sua realidade.

Ciclo do sistema utilizando Mobile Cloud Computing

A seguir, um esquema representando o funcionamento do algoritmo de detecção de linhas de plantio associada à MCC é apresentado.

Figura 28. Esquema de sistema de Mobile Cloud Computing associado à detecção de linhas e falhas de plantio.



Pelo esquema apresentado acima, temos os dados adquiridos pelo VANT sendo diretamente repassados para a nuvem. O usuário, de porte de algum dispositivo móvel, tem acesso à nuvem e pode realizar solicitações, acessar os dados transferidos ao servidores e manipula-los.

Na nuvem, os dados recebidos são processados e armazenados. Assim, o usuário, através de seus dispositivos conectados à uma rede, é capaz de verificar as imagens capturadas, o ortomosáico, solicitar e visualizar as linhas e falhas de plantio sobrepostas sobre o ortomosáico.

Caso tenha interesse, outras aplicações e serviços podem ser integrados na plataforma em nuvem. Isso não acarretará em sobrecarga dos dispositivos móveis ou dificuldades em acessar os dados, tendo em vista que toda sua base está alocada virtualmente e a nuvem tem sua infraestrutura pode ser desenvolvida com capacidade de alocar mais recursos conforme necessário.

4 RESULTADOS E DISCUSSÕES

Para validação do algoritmo proposto, foram realizados testes utilizando o AG associado a TDW e o AG puro para analisar a velocidade de retorno de resultados, além de sua precisão. A relevância de aplicação de uma multilimiarização frente a aplicação de uma limiarização simples (binarização direta) também é apresentada, tendo como comparativo o retorno de resultado gerado pelo THPP.

Por se tratar de um algoritmo e não um software completo, os resultados aqui apresentados levam em consideração secções de uma plantação de cana-de-açúcar (fornecidas pela Sensix) e não o ortomosaico como um todo. Assim, a utilização do mesmo depende ainda de refinamentos e aprimoramentos para a produção e distribuição como ferramenta para uso no mercado de foco, além de novos testes de aplicação.

Os *hardwares* e *softwares* utilizados durante as simulações estão listados na tabela abaixo, sendo a referência dos resultados da simulação.

Tabela 2. Informações dos softwares/hardwares utilizados na simulação.

Hardware/Software	Informações
Modelo:	Ideapad 330S 81JQ0002BR
Fabricante:	Lenovo Group Ltd.
Processador:	AMD Ryzen™ 7 2700U (2,20 GHz)
RAM:	8,00 GB (utilizável: 6,90 GB)
Sistema Operacional:	Windows 10 Home Single Language (64 bit)
Linguagem:	Python 2.7 + bibliotecas associadas
IDE utilizado:	Visual Studio Code 1.44.0

4.1 Análise do AG proposto

Um ponto chave no desenvolvimento do trabalho é o Algoritmo Genético associado à Transformada Discreta de Wavelet, o qual propicia o desenvolvimento com eficiência e acurácia para a localização do ponto de binarização ideal ao sistema para o desenrolar do processo de localização das linhas de plantio utilizando a Transformada de Hough Probabilística Progressiva.

Para os testes, duas imagens de conhecidas na comunidade quando tratamos do assunto de segmentação de imagens foram utilizadas: *Lenna* (512×512 pixels) e *Peppers* (512×512 pixels). Ambas as imagens em escala de cinza.

Os experimentos levaram em consideração 3 metodologias:

- Aplicação pura da adaptação de Otsu para multilimiarização
- Aplicação do AG da proposta sem o auxílio da TDW
- Aplicação do AG integrado com a TDW

Para o AG, os seguintes parâmetros utilizados, seguem os apresentados na metodologia:

- Cruzamento proporcional: 70% de ocorrência
- Mutação swap: 5% de ocorrência
- Elitismo: 5% da população
- Função de aptidão: Otsu
- Seleção por torneio: 2 à 2 com 70% de taxa de vitória
- Condição de parada: $N = 100$ gerações
- População para AG integrado sem a TDW: $P = 100$
- População para AG integrado com a TDW: $P = 38$
- Nível de redução da TDW: $r = 3$

A diferença entre populações para os casos se dá pela complexidade dos cromossomos, tendo em vista que um deles terá 256 posições por utilizar todo o espectro da escala de cinza. O valor de P foi pensado para suprir as necessidades de diversidade da população e, ao mesmo tempo, não ser impor um volume além do necessário para a convergência estável do AG sem uso do TDW.

Figura 29. Imagens de teste em escala de cinza: Lenna (à esquerda) e Peppers (à direita).



Fonte: <http://78.108.103.11:11080/~fojtik/gallery/gray.htm> , acesso em: abril, 2020.

Os resultados obtidos são fruto da média de 3 ciclos de cada um dos métodos e estão apresentados na tabela a seguir:

Tabela 3. Métodos, limiares e tempo para sua computação em imagens de teste.

Imagem	Método	3 limiares	CPU time (s)	4 limiares	CPU time (s)
Lenna	Otsu	79 – 124 – 170	448.988	75 – 115 – 145 – 175	>>>> 600.000
	AG sem TDW	79 – 125 – 170	16.258	75 – 113 – 145 – 180	18.081
	GA + DWT (proposta)	80 – 128 – 168	3.174	72 – 112 – 144 – 176	3.871
Peppers	Otsu	63 – 119 – 168	398.423	56 – 90 – 128 – 170	>>>> 600.000
	AG sem TDW	64 – 120 – 168	15.798	50 – 89 – 129 – 171	16.796
	GA + DWT (proposta)	64 – 120 – 168	3.115	56 – 96 – 128 – 168	3.650

Fonte: O Autor no artigo: *A Fast Multilevel Thresholding Approach for Image Segmentation Using Genetic Algorithm and an Application in Crop Rows Detection*, COBEM 2019.

Três e quatro limiares foram utilizados para mostrar o incremento médio de tempo gerado pelo aumento de um para o outro. Embora nosso foco seja empregar quatro limiares, apresentar essa diferenciação traz a ideia de como o método pode afetar o tempo necessário para computação dos resultados.

O método de Otsu, puramente aplicado, realiza uma busca exaustiva por todas as possibilidades que podem levar à maximização da variância entre classes. Diferente das duas outras aplicações relatadas, que partem para uma aplicação heurística, o método de Otsu perde

sua eficiência conforme expandido para a busca de múltiplos limiares, o que é facilmente observado quando observamos o seu tempo de execução na Tabela X.

Considerando que para a binarização temos L níveis de busca, sendo L a quantidade de níveis na escala utilizada pelo histograma, quando passamos para uma aplicação de multilimiarização, temos que as posições a serem pesquisadas para encontrar os melhores limiares sobem conforme equação:

$$L \times (L-1) \times \dots \times (L-t), \text{ sendo } t \text{ o número de limiares.} \quad (18)$$

Ao utilizarmos a função de Otsu como função de aptidão dentro de um AG, é possível verificar uma grande queda no tempo de resposta para a obtenção dos limiares. Como a pesquisa se dá de modo aleatório, devido a geração aleatória dos indivíduos contendo possíveis soluções o processo do algoritmo usa Otsu como apoio na descoberta de uma boa solução ao problema.

Embora os AG's tenham variações em sua resposta, a Tabela X mostra que os limiares aproximados são bem próximos dos exatos fornecidos pelo método de Otsu. Assim, observamos que o uso de um AG trás melhorias em tempo sem grandes perdas na acurácia.

Finalmente, ao compararmos os resultados com o AG associado a TDW, temos que essa provê o melhor resultado em tempo – consideravelmente menor que o do AG puro – e manter qualidade na entrega dos limiares.

Esses resultados mostram que, conforme apresentado, a redução dos detalhes da imagem quando da convolução da mesma através da TDW possibilita não só a redução do tempo de execução quanto garante, ao reconstruirmos o sinal, que os limiares apresentem uma boa acurácia com relação aos valores esperados.

4.2 Análise da aplicação para a detecção de linhas e falhas de plantio

Para essa etapa, faremos uso de uma secção do ortomosaico para apresentação de resultados.

Ao fim do pré-processamento com a aplicação do AG, temos os valores que melhor fariam a multilimiarização da imagem. Com isso, partimos para a binarização da imagem, esqueletização e, por fim, aplicação da THPP para detecção inicial das linhas de plantio.

Abaixo temos a secção exemplo e outras figuras detalhando informações do seu processamento.

Figura 30. Secção do ortomosáico utilizada para testes.




Figura 31. Histograma em escala de cinza da secção utilizada do ortomosáico.

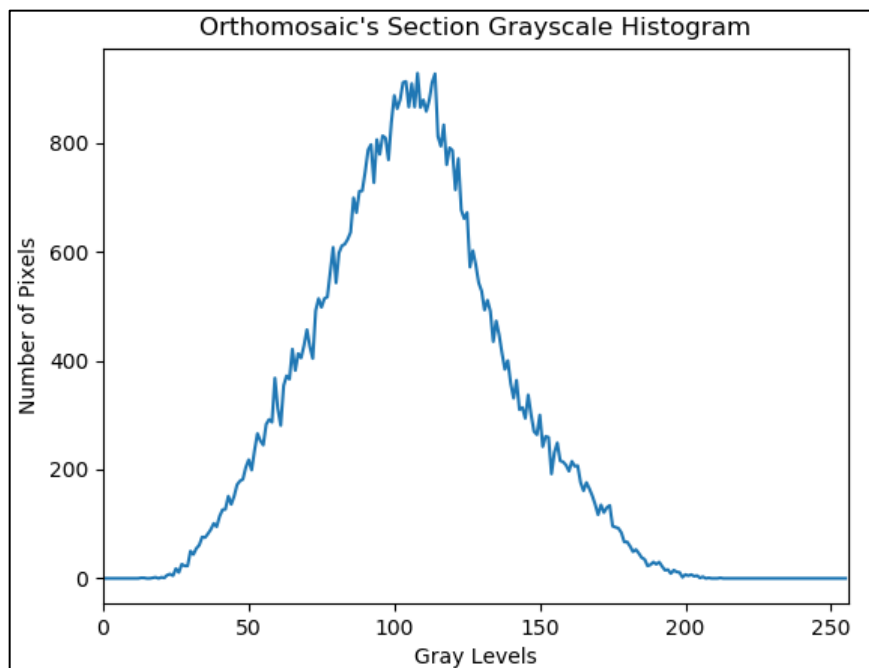


Figura 32. Figura 31. Histograma em escala de cinza da secção utilizada do ortomosáico após a convolução com a TDW.

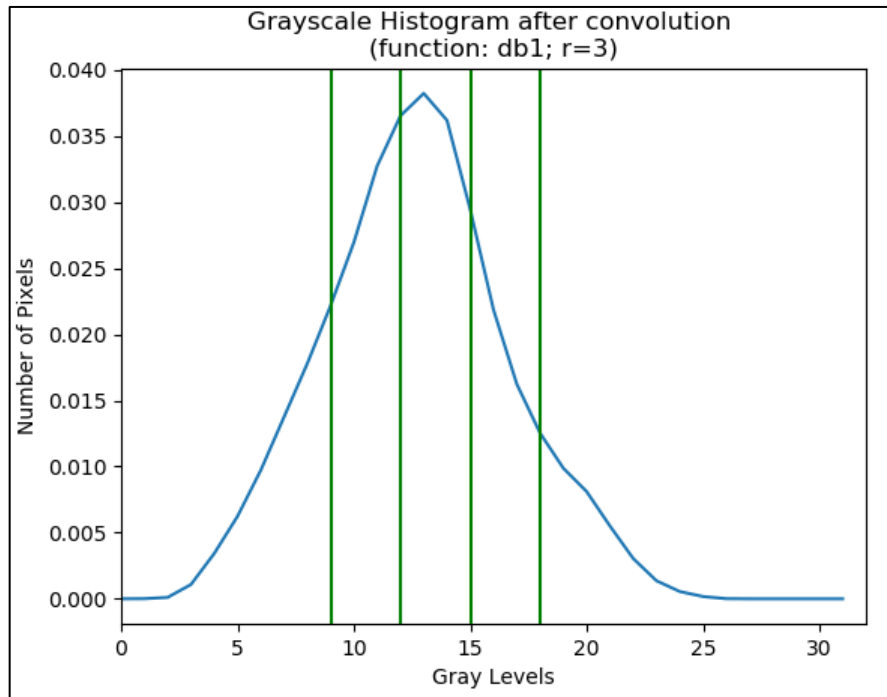


Figura 33. Histograma em escala de cinza da secção do ortomosáico com limiares reconstituídos para escala original. O limiar em preto (144) representa aquele que será utilizado para binarização.

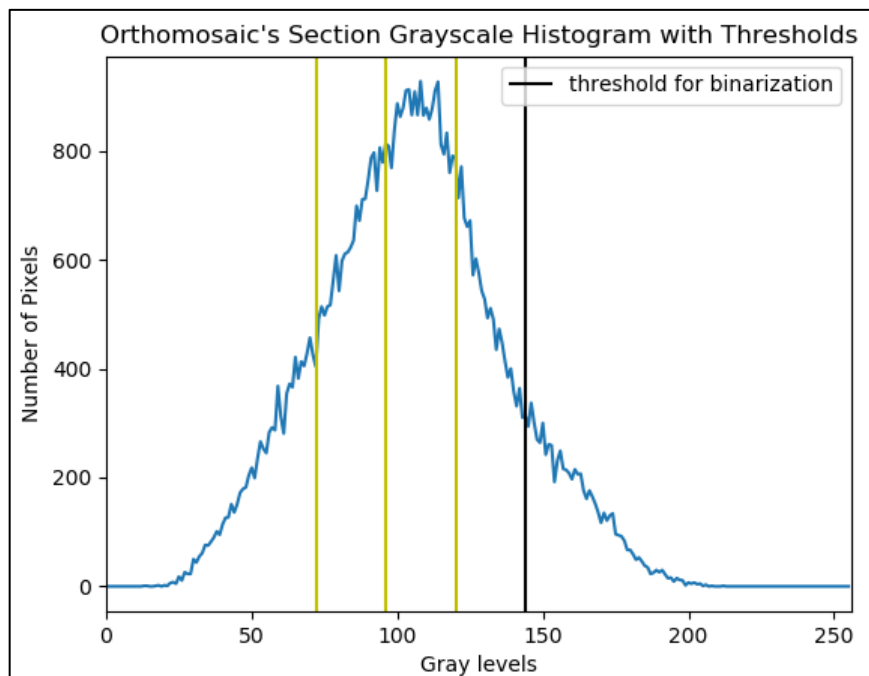
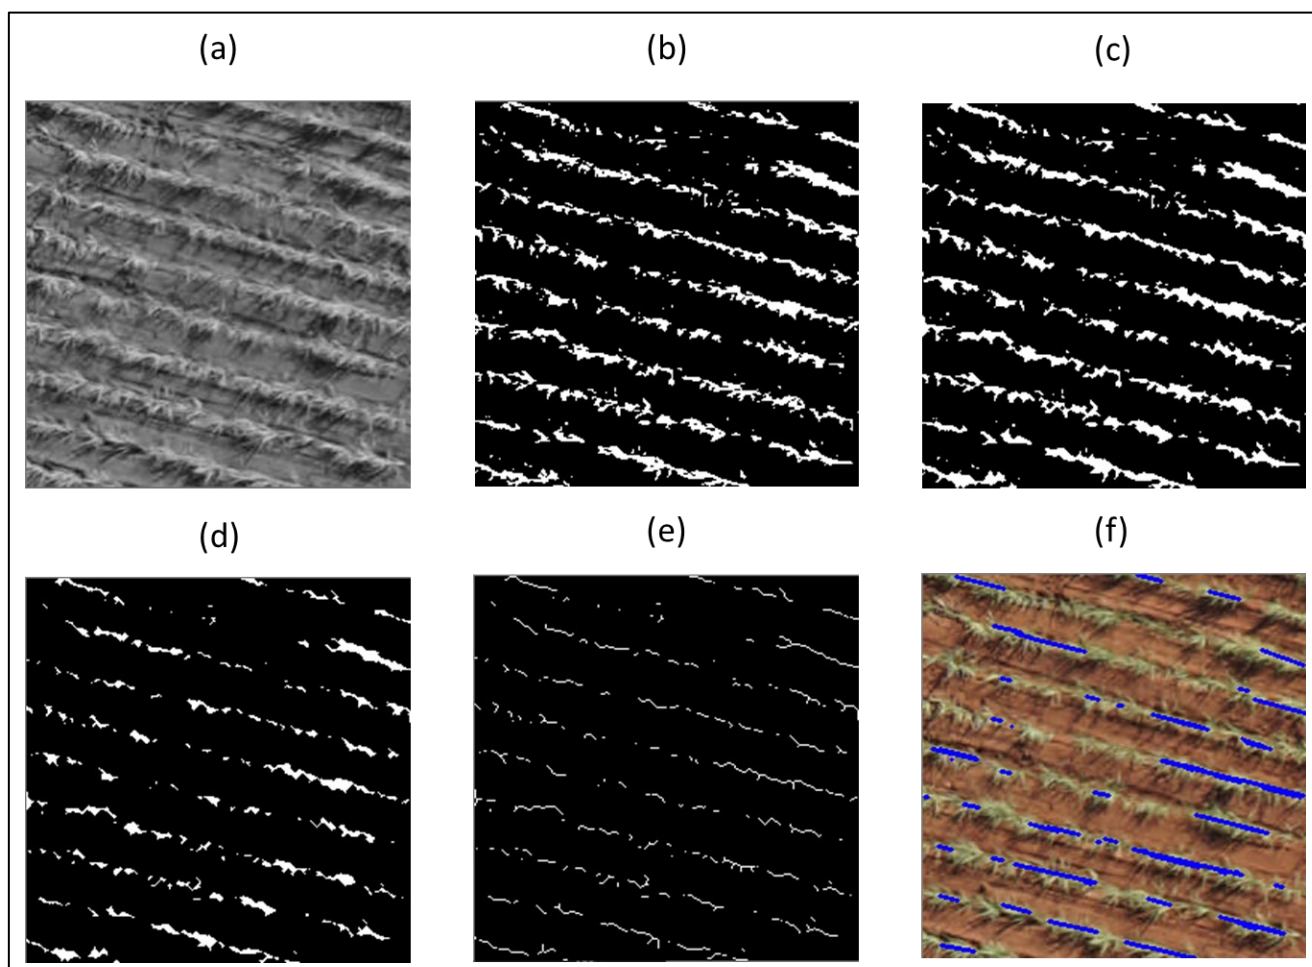



Figura 34. Passos do algoritmo: (a) conversão em escala de cinza; (b) binarização utilizando o limiar encontrado pelo AG; (c) operação morfológica de fechamento; (d) operação morfológica de erosão; (e) esquelitização; (f) THPP aplicada no esqueleto sob a imagem em escala de cor original da secção.




Conforme apresentado anteriormente, faz-se necessário um refinamento das retas localizados pela THPP. Desse refinamento, temos a seguinte figura:

Figura 35. Retas contínuas produzidas após o refinamento dos segmentos gerados pela THPP.



Analisando o entorno das linhas de plantio geradas, podemos detectar as regiões de falha

Figura 36. Secção com linhas de plantio (em azul) e falhas (em vermelho) detectadas em sobreposição à imagem original.




As falhas identificadas, quando as secções são reconstruídas no ortomosáico podem ser analisadas em sua dimensão real, com o auxílio do georreferenciamento.

4.3 Apontamento de melhorias

A seguir, temos a união de 4 secções e sua demarcação.

Figura 37. Conexão de 4 secções da plantação e a detecção de suas linhas e falhas. Em amarelo, temos a demarcação dos limites de cada secção.




Através da Fig. 37 podemos verificar que, ao centro da imagem, certas partes da plantação não têm sua linha detectada.

Isso se dá pelo fato de as regiões limite da imagem, em muitos casos, conterem uma porção pequena da fila da plantação, de modo que a THPP normalmente não detecta nenhum desses pontos.

Para contornar esse problema durante a reconstrução da imagem faz-se uso de uma janela auxiliar, cujo propósito é a detecção dessas regiões. Temos, então, a aplicação de detecção das

linhas nessa janela, que é formada por uma área que contém as regiões de conexão entre as secções, conforme Fig. 38.

Figura 38. Secções da plantação de cana-de-açúcar e identificação da janela auxiliar.




Embora a detecção das linhas seja visualmente satisfatória, como apresentado anteriormente na Fig. 36 e, até mesmo, na Fig. 37, outros aspectos técnicos ainda precisam ser melhorados.

A exemplo, temos as condições climáticas e o tipo de vegetação: mesmo que apresentado bons resultados na situação apresentada é interessante que o algoritmo se torne mais responsivo para outras vegetações e em condições pouco menos ideais de exposição de luz. Isso o tornaria mais abrangente para aplicação em cultivos outros que não de cana-de-açúcar, por exemplo, ou da própria cana em situações adversas.

Outra questão técnica diz respeito aos falsos positivos para falhas, como pode ser observado na Fig. 39. Em alguns casos, a tratativa das falhas em etapas de processamento, como na imagem binária, pode levar a algumas inconsistências que THPP não consegue auxiliar na resolução por não representar todos os segmentos possíveis.

Figura 39. Identificação de falsos positivos. Na imagem à direita, a falha detectada mais acima vai além do limite da mesma e, a falha mais abaixo deveria ser inexistente. A imagem à esquerda facilita a visualização das indicações.



Esses falsos positivos podem ser tratados com uma validação utilizando a imagem em RGB, mas ainda está em análise o processo que torne o procedimento o menos custoso possível ao sistema, visando mantê-lo rápido e simples, para um processamento ágil e de baixo custo computacional.

Uma melhor adaptação da técnica de Transformada de Hough probabilística utilizada pode auxiliar em redução do tempo na detecção de linhas contínuas, tal como a adaptação do AG com o uso da TDW auxiliou na celeridade do processo de segmentação das seções de imagem.

Além disso, refinamentos podem ser feitos para uma integração com outros softwares (ou desenvolvimento de um novo) voltados para análise em AP, não apenas para a detecção de falhas, mas para o uso dessas informações e dos segmentos da multilíngüarização para outras finalidades de interesse, como desenvolvimento de rotas para equipamentos autônomos, cálculo de utilização da área cultivável, análise de crescimento lateral da vegetação, identificação de ervas daninhas, etc.

Por fim, a integração com a MCC é relevante para o avanço da aplicação e pode ser construída em plataformas como a AWS (*Amazon Web Service*), serviço em nuvem da Amazon, amplamente difundido na construção de aplicativos e portais mais robustos.

Todos os apontamentos auxiliam na construção de uma ferramenta comercial viável, buscando um consumo de recursos que possa ser otimizado no processamento de imagens e, conseqüentemente, tentando reduzir gastos financeiros não só para sua própria manutenção, mas na manutenção de áreas agrícolas auxiliadas pela AP, visando lucro ao empreendedor.

5 CONCLUSÕES

O trabalho apresentou um método computacional desenvolvido para a detecção de linhas e falhas de plantio utilizando como base secções de um mapa ortomosaico – construído a partir de imagens aéreas adquiridas por um VANT – cedido pela empresa SENSIX.

Para simplificar a detecção das linhas de plantio, o ortomosaico foi dividido em secções menores cuja trajetória da vegetação em cada quadro pode ser tratada como sendo retilínea. Assim, os testes realizados utilizaram essas secções para que, através de um algoritmo, as linhas pudessem ser identificadas, bem como as falhas dentro nessas linhas de plantio, por meio de uma aplicação probabilística da Transformada de Hough.

No intuito de desenvolver um método com baixa exigência computacional, tempo de resposta reduzido e, ainda assim, mantendo boa acurácia, a estratégia utilizada foi a implementação de um algoritmo genético para multilimiarização que tivesse como entrada o sinal de aproximação gerado pela convolução da secção do ortomosaico (em escala de cinza) pela Transformada Discreta de Wavelet. A aplicação desse algoritmo tratou do pré-processamento inicial da secção, abrindo caminho para a aplicação da Transformada de Hough Probabilística Progressiva.

O Algoritmo Genético associado a TDW auxiliou numa melhor identificação do objeto foco da aplicação: a vegetação de cana-de-açúcar plantada; possibilitando uma binarização aperfeiçoada da secção. Disso, partiu-se para o tratamento morfológico matemático afim de gerar uma representação em linhas de 1-bit da cana, por meio de um processo denominado esqueletização, para a aplicação do método de Transformada de Hough Probabilístico Progressivo.

Comparando o AG associado a TDW com a aplicação sem essa associação e outro método não-heurístico de investigação (proposto por Otsu), o algoritmo para de multilimiarização projetado mostrou os resultados mais eficientes em velocidade e, conforme desejado, manteve boa aproximação com relação aos valores de limiares detectados.

O uso de informações da etapa de pré-processamento inicial também proporcional uma aplicação satisfatória, ao final, da Transformada de Hough Probabilística Progressiva, identificando traços referentes as linhas de plantio.

Ao final, fez-se necessário um aprimoramento dos resultados encontrados pela Transformada de Hough, para a definição de linhas contínuas. A partir disso, foram obtidas com sucesso as linhas e falhas de plantio na secção exemplo utilizada para simulação.

O método computacional desenvolvido cumpriu com a proposta de aplicação e, embora ainda em fase inicial, tem resultados animadores para futuras aplicações reais de mercado. Além disso, suas características pautadas num retorno rápido de resultado e o anseio de associação com uma estratégia voltada para *Mobile Cloud Computing* são tópicos de interesse para o desenvolvimento de amplas pesquisas em trabalhos futuros, tendo em vista a evolução e os investimentos no paradigma ao longo dos anos. Dentro os tópicos para futuras aplicações, destacam-se a associação dos dados obtidos em uma plataforma de georreferenciamento para uma análise integrada, a transferência de recursos para computação dos dados e imagens em nuvem e o desenvolvimento integrados de softwares para a centralização de informações.

REFERENCIAS

- ABDULLAHI, H. S.; MAHIEDDINE, F.; SHERIFF, R. E. Technology Impact on Agricultural Productivity: A Review of Precision Agriculture Using Unmanned Aerial Vehicles. **Wireless and Satellite Systems Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering**, p. 388–400, 2015. https://doi.org/10.1007/978-3-319-25479-1_29
- ABER, J. S.; MARZOLFF, I.; RIES, J. B. **Small-format aerial photography: principles, techniques and geoscience applications**. Amsterdam: Elsevier, 2010.
- AKHERFI, K.; GERNDT, M.; HARROUD, H. Mobile cloud computing for computation offloading: Issues and challenges. **Applied Computing and Informatics**, v. 14, n. 1, p. 1–16, 2018. <https://doi.org/10.1016/j.aci.2016.11.002>
- ANDRADE, J. B. **Fotogrametria**, SBEE, Curitiba, 1989, p. 258.
- ASRANI, P. Mobile Cloud Computing. **International Journal of Engineering and Advanced Technology**, v. 2, n. 4, p. 606–609, 2013.
- AUVSI. **The Economic Impact of Unmanned Aircraft Systems Integration in the United States**. [s.l.] Association for Unmanned Vehicle Systems International, Mar. 2013. Disponível em: <<https://www.auvsi.org/our-impact/economic-report>>. Acesso em: mai. 2019.
- BAY, H. et al. Speeded-Up Robust Features (SURF). **Computer Vision and Image Understanding**, v. 110, n. 3, p. 346–359, 2008. <https://doi.org/10.1016/j.cviu.2007.09.014>
- BEHMANN, J. et al. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. **Precision Agriculture**, v. 16, n. 3, p. 239–260, 2014. <https://doi.org/10.1007/s11119-014-9372-7>
- BLUM, H. A transformation for extracting new descriptors of shape. **Models for the Perception of Speech and Visual Form**, 1967.
- BOSSU, J. et al. Wavelet transform to discriminate between crop and weed in perspective agronomic images. **Computers and Electronics in Agriculture**, v. 65, n. 1, p. 133–143, 2009. <https://doi.org/10.1016/j.compag.2008.08.004>
- BRASIL. **Agricultura de precisão. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Desenvolvimento Agropecuário e Cooperativismo**. Brasília: Mapa/ACS, 2014. 36 p. (Agenda Estratégica 2014 – 2030). Disponível em: <<http://www.agricultura.gov.br/assuntos/sustentabilidade/tecnologia-agropecuaria/agricultura-de-precisao-1/arquivos-de-agricultura-de-precisao/agenda-estrategica-do-setor-de-agricultura-de-precisao.pdf/view>>. Acesso em: abril de 2019.
- BROSNAN, T.; SUN, D.-W. Inspection and grading of agricultural and food products by computer vision systems—a review. **Computers and Electronics in Agriculture**, v. 36, n. 2–3, p. 193–213, 2002. [https://doi.org/10.1016/S0168-1699\(02\)00101-1](https://doi.org/10.1016/S0168-1699(02)00101-1)

CAMARGO, A.; SMITH, J. Image pattern classification for the identification of disease causing agents in plants. **Computers and Electronics in Agriculture**, v. 66, n. 2, p. 121–125, 2009. <https://doi.org/10.1016/j.compag.2009.01.003>

CHANG, S.; YU, B.; VETTERLI, M. Image denoising via lossy compression and wavelet thresholding. **Proceedings of International Conference on Image Processing**, 2000.

CHON, J.; KIM, H.; LIN, C. S. Seam-line determination for image mosaicking: a technique minimizing the maximum local mismatch and the global cost. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 86-92, 2010. <https://doi.org/10.1016/j.isprsjprs.2009.09.001>

CHOU, J. J.; CHEN, C. P.; YEH, J. T. Crop identification with wavelet packet analysis and weighted Bayesian distance. **Computers and Electronics in Agriculture**, v. 57, n. 1, p. 88–98, 2007. <https://doi.org/10.1016/j.compag.2007.02.007>

COELHO, A. M. **Agricultura de precisão manejo da variabilidade espacial e temporal dos solos e culturas**. Sete Lagoas: Embrapa Milho e Sorgo, 2005.

CUBERO, S. et al. Optimised computer vision system for automatic pre-grading of citrus fruit in the field using a mobile platform. **Precision Agriculture**, v. 15, n. 1, p. 80–94, 2013. <https://doi.org/10.1007/s11119-013-9324-7>

Cybersecurity Technologies Service. ABI Research. [Online]. Disponível em: <https://www.abiresearch.com/press/abi-research-expects-cloud-computing-and-big-data/>.

Acesso em: 20 Abr. 2020.

DUDA, R. O.; HART, P. E. Use of the Hough transformation to detect lines and curves in pictures. **Communications of the ACM**, v. 15, n. 1, p. 11–15, Jan. 1972. <https://doi.org/10.1145/361237.361242>

FERNANDES, P. **Estimativa da Produtividade de Milho (Zea Mays L.) Através de Imagens Multiespectrais Obtidas Por Veículo Aéreo Não Tripulado**. Dissertação (Dissertação em Agricultura de Precisão) – Colégio Politécnico, UFSM. Rio Grande do Sul, p. 78. 2016. Disponível em: <https://repositorio.ufsm.br/handle/1/4842>. Acesso em: ago. 2019.

FERNANDO, N.; LOKE, S. W.; RAHAYU, W. Mobile Cloud Computing: A survey. **Future Generation Computer Systems**, v. 29, n. 1, p. 84–106, 2013. <https://doi.org/10.1016/j.future.2012.05.023>

FILHO, O. M.; NETO, H. V. **Processamento digital de imagens**. Rio de Janeiro (RJ): BRASPORT, 1999.

GARCÍA-SANTILLÁN, I. D. et al. Automatic detection of curved and straight crop rows from images in maize fields. **Biosystems Engineering**, v. 156, p. 61–79, 2017. <https://doi.org/10.1016/j.biosystemseng.2017.01.013>

GONZÁLEZ RAFAEL C.; WOODS, R. E. **Digital image processing**. Tradução . Upper-Saddle River, NJ: Prentice Hall, 2002.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. Rio de Janeiro: Pearson Prentice Hall, 2010.

GOSWAMI, J. C.; CHAN, A. K. **Fundamentals of wavelets: theory, algorithms and applications**. Tradução. Oxford: Wiley-Blackwell, 2011.
<https://doi.org/10.1002/9780470926994>

GREGO, C. R. et al. Geoestatística aplicada a agricultura de precisão. *In*: BERNARDI, A. C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. cap. 5, p. 74-83. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/114688/1/Agricultura-de-precisao-cap.5.pdf>. Acesso em: ago. 2019.

GUIJARRO, M. et al. Discrete wavelets transform for improving greenness image segmentation in agricultural images. **Computers and Electronics in Agriculture**, v. 118, p. 396–407, 2015. <https://doi.org/10.1016/j.compag.2015.09.011>

HARDIN, P. J.; HARDIN, T. J. Small-Scale Remotely Piloted Vehicles in Environmental Research. **Geography Compass**, v. 4, n. 9, p. 1297–1311, Jan. 2010. <https://doi.org/10.1111/j.1749-8198.2010.00381.x>

JENSEN, J. R. **Sensoriamento Remoto do ambiente: Uma perspectiva sobre recursos terrestres**. São José dos Campos, SP. Ed. Parêntese, 2009.

JIANG, G.; WANG, Z.; LIU, H. Automatic detection of crop rows based on multi-ROIs. **Expert Systems with Applications**, v. 42, n. 5, p. 2429–2441, 2015. <https://doi.org/10.1016/j.eswa.2014.10.033>

KAPUR, J.; SAHOO, P.; WONG, A. A new method for gray-level picture thresholding using the entropy of the histogram. **Computer Vision, Graphics, and Image Processing**, v. 29, n. 1, p. 140, 1985. [https://doi.org/10.1016/S0734-189X\(85\)90156-2](https://doi.org/10.1016/S0734-189X(85)90156-2)

KITTLER, J.; ILLINGWORTH, J. Minimum error thresholding. **Pattern Recognition**, v. 19, n. 1, p. 41–47, 1986. [https://doi.org/10.1016/0031-3203\(86\)90030-0](https://doi.org/10.1016/0031-3203(86)90030-0)

KUMAR, L. et al. Mobile Cloud Computing. **International Journal of Research in Information Technology**, v. 2, n. 9, p. 787–792, 2014.

LEBOEUF, J. Practical Applications of Remote Sensing Technology—An Industry Perspective. **HortTechnology**, p. 475–480, 2000. <https://doi.org/10.21273/HORTTECH.10.3.475>

LELONG, C. et al. Assessment of Unmanned Aerial Vehicles Imagery for Quantitative Monitoring of Wheat Crop in Small Plots. **Sensors**, v. 8, n. 5, p. 3557–3585, 2008. <https://doi.org/10.3390/s8053557>

LINDEN, R. **Algoritmos genéticos: uma importante ferramenta da inteligência computacional**. Tradução. Rio de Janeiro: Brasport, 2008.

Lloyd, D. E. Automatic target classification using moment invariants of image shapes. Technical Report **RAE IDN AW126**, Farnborough, U.K., December 1985

LUCIO, L. A. de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. *In*: BERNARDI, A. C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. cap. 8, p. 109-134. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/114264/1/CAP-8.pdf>. Acesso em: ago. 2019.

MAHESWARI, D.; RADHA, V. Comparison of Layer and Block Based Classification in Compound Image Compression. **International Journal of Computer Science and Information Technologies**, v. 2, n. 2, p. 888–890, 2011.

MATAS, J.; GALAMBOS, C.; KITTLER, J. Robust Detection of Lines Using the Progressive Probabilistic Hough Transform. **Computer Vision and Image Understanding**, v. 78, n. 1, p. 119–137, 2000. <https://doi.org/10.1006/cviu.1999.0831>

MEDEIROS, F. A. **Desenvolvimento de um veículo aéreo não tripulado para aplicação em agricultura de precisão**. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Santa Maria. Santa Maria, p. 102, 2007. Disponível em: <http://repositorio.ufsm.br/handle/1/7584>. Acesso em ago. 2019.

MELL, P. M.; GRANCE, T. M. The NIST definition of cloud computing. 2011. <https://doi.org/10.6028/NIST.SP.800-145>

MELL, P.; GRANCE, T. **The NIST Definition of Cloud Computing**. [s.l.: s.n.]. Disponível em: <<https://nvlpubs.nist.gov/nistpubs/Legacy/SP/nistspecialpublication800-145.pdf>>. Acesso em: 20 apr. 2020.

MITCHELL, M. **An introduction to genetic algorithms**. Tradução . Cambridge, MA: MIT, 1999.

MOLIN, J. P. et al. **Agricultura de Precisão**. 1 ed. São Paulo: Oficina de Textos, 2015.

MORIYA, E. A. S. **Identificação de bandas espectrais para detecção de cultura de cana-de-açúcar sadia e doente utilizando câmara hiperespectral embarcada em VANT**. Tese (Tese em Ciências Cartográficas) – FCT, UNESP. São Paulo, p. 147. 2015. Disponível em: <http://hdl.handle.net/11449/133961>. Acesso em: ago. 2019.

NAMDE, A. **Mobile Application Market – Global Opportunity Analysis and Industry Forecast, 2016 - 2023**. [s.l.] Allied Market Research, Mai. 2017. Disponível em: <<https://www.alliedmarketresearch.com/mobile-application-market>>. Acesso em: mai. 2019.

NOOR, T. H. et al. Mobile cloud computing: Challenges and future research directions. **Journal of Network and Computer Applications**, v. 115, p. 70–85, 2018. <https://doi.org/10.1016/j.jnca.2018.04.018>

OLIVO, J. Automatic Threshold Selection Using the Wavelet Transform. **CVGIP: Graphical Models and Image Processing**, v. 56, n. 3, p. 205–218, 1994. <https://doi.org/10.1006/cgip.1994.1019>

PALIWAL, J. et al. Evaluation of Neural Network Architectures for Cereal Grain Classification using Morphological Features. **Journal of Agricultural Engineering Research**, v. 79, p. 361–370, 2001. <https://doi.org/10.1006/jaer.2001.0724>

- PAYNE, A. et al. Estimation of mango crop yield using image analysis – Segmentation method. **Computers and Electronics in Agriculture**, v. 91, p. 57–64, 2013. <https://doi.org/10.1016/j.compag.2012.11.009>
- PEREIRA, D. C.; RAMOS, R. P.; NASCIMENTO, M. Z. D. Segmentation and detection of breast cancer in mammograms combining wavelet analysis and genetic algorithm. **Computer Methods and Programs in Biomedicine**, v. 114, n. 1, p. 88–101, 2014. <https://doi.org/10.1016/j.cmpb.2014.01.014>
- POLDER, G. et al. Automatic detection of tulip breaking virus (TBV) in tulip fields using machine vision. **Biosystems Engineering**, v. 117, p. 35–42, 2014. <https://doi.org/10.1016/j.biosystemseng.2013.05.010>
- PUN, T. Entropic thresholding, a new approach. **Computer Graphics and Image Processing**, v. 16, n. 3, p. 210–239, 1981. [https://doi.org/10.1016/0146-664X\(81\)90038-1](https://doi.org/10.1016/0146-664X(81)90038-1)
- QUIROZ, R. A. A.; GUIDOTTI, F. P.; BEDOYA, A. E. A method for automatic identification of crop lines in drone images from a mango tree plantation using segmentation over YCrCb color space and Hough transform. **2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)**, 2019.
- R. Klette. **Concise Computer Vision**. Springer, Londres, 2014, p. 429. <https://doi.org/10.1007/978-1-4471-6320-6>
- RAJA, C. V.; CHITRA, K.; JONAFARK, M. A Survey on Mobile Cloud Computing. **International Journal of Scientific Research in Computer Science, Engineering and Information Technology**, v. 3, n. 3, p. 2096–2100, 2018.
- RASTOGI, A.; ARORA, R.; SHARMA, S. Leaf disease detection and grading using computer vision technology & fuzzy logic. **2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)**, 2015. <https://doi.org/10.1109/SPIN.2015.7095350>
- SECRETARIA DE DESENVOLVIMENTO E COMPETITIVIDADE INDUSTRIAL. **Estudo sobre a indústria brasileira e europeia de veículos aéreos não tripulados**. 2017.
- SHAPIRO, L. G.; STOCKMAN, G. C. **Computer vision**. Upper Saddle River, NJ: Prentice Hall, 2000.
- SHIH, F. Y. **IMAGE PROCESSING AND MATHEMATICAL MORPHOLOGY: fundamentals and applications**. Place of publication not identified: CRC Press, 2017. <https://doi.org/10.1201/9781420089448>
- SHIRATSUCHI, L. S. et al. Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. *In*: BERNARDI, A. C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. cap. 4, p. 58-73. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/114687/1/Agricultura-de-precisao-cap.4.pdf>. Acesso em: ago. 2019.
- SHIRAZ, M. et al. Investigation on runtime partitioning of elastic mobile applications for mobile cloud computing. **The Journal of Supercomputing**, v. 67, n. 1, p. 84–103, Feb. 2013. <https://doi.org/10.1007/s11227-013-0988-6>

SHIRISH S. P.; BHALERAO, S. A. Precision farming: The most scientific and modern approach to sustainable agriculture. **International Research Journal of Science and Engineering**, v. 1, n. 2, p. 21–30, 2013.

SILVA JR, U. C. **Proposta para o desenvolvimento de uma ortofotocarta atualizada da UFMG**. Monografia (Especialização em Geoprocessamento) – Instituto de Geociências, UFMG. Belo Horizonte, p. 44. 2004. Disponível em: <http://www.csr.ufmg.br/geoprocessamento/publicacoes/Ubirajara2004-parte1de2.PDF>. Acesso em: ago. 2019.

SØGAARD, H.; OLSEN, H. Determination of crop rows by image analysis without segmentation. **Computers and Electronics in Agriculture**, v. 38, n. 2, p. 141–158, 2003. [https://doi.org/10.1016/S0168-1699\(02\)00140-0](https://doi.org/10.1016/S0168-1699(02)00140-0)

STOLF, R. **Metodologia de avaliação de falhas nas linhas de cana-de-açúcar**. STAB, Piracicaba, v.4, n.6, p.22-36, 1986.

SWAIN, K. C.; THOMSON, S. J.; JAYASURIYA, H. P. W. Adoption of an Unmanned Helicopter for Low-Altitude Remote Sensing to Estimate Yield and Total Biomass of a Rice Crop. **Transactions of the ASABE**, v. 53, n. 1, p. 21–27, 2010. <https://doi.org/10.13031/2013.29493>

TIAN, H. et al. Computer vision technology in agricultural automation - A review. *Information Processing in Agriculture*, v. 7, n. 1, p. 1–19, 2020. <https://doi.org/10.1016/j.inpa.2019.09.006>

TILLET, R. Image analysis for agricultural processes: a review of potential opportunities. **Journal of Agricultural Engineering Research**, v. 50, p. 247–258, 1991. [https://doi.org/10.1016/S0021-8634\(05\)80018-6](https://doi.org/10.1016/S0021-8634(05)80018-6)

TOMASSINI, M. A Survey Of Genetic Algorithms. **Annual Reviews of Computational Physics III**, p. 87–118, 1995. https://doi.org/10.1142/9789812830647_0003

VIDOVIĆ, I.; CUPEC, R.; HOCENSKI, Ž. Crop row detection by global energy minimization. **Pattern Recognition**, v. 55, p. 68–86, 2016. <https://doi.org/10.1016/j.patcog.2016.01.013>

WALKER, J. S. **A primer on wavelets and their scientific applications**. Tradução . Boca Raton FL: Chapman & Hall/CRC, 2008.

WU, D.; SUN, D.-W. Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review — Part I: Fundamentals. **Innovative Food Science & Emerging Technologies**, v. 19, p. 1–14, 2013. <https://doi.org/10.1016/j.ifset.2013.04.014>

WU, J. et al. Comparison of petiole nitrate concentrations, SPAD chlorophyll readings, and QuickBird satellite imagery in detecting nitrogen status of potato canopies. **Field Crops Research**, v. 101, n. 1, p. 96–103, 2007. <https://doi.org/10.1016/j.fcr.2006.09.014>

YIN, P.-Y. A fast scheme for optimal thresholding using genetic algorithms. **Signal Processing**, v. 72, n. 2, p. 85–95, 1999. [https://doi.org/10.1016/S0165-1684\(98\)00167-4](https://doi.org/10.1016/S0165-1684(98)00167-4)

ZHANG, B. et al. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. **Food Research International**, v. 62, p. 326–343, 2014.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, v. 13, n. 6, p. 693–712, 2012. <https://doi.org/10.1007/s11119-012-9274-5>

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture—a worldwide overview. **Computers and Electronics in Agriculture**, v. 36, n. 2-3, p. 113–132, 2002. [https://doi.org/10.1016/S0168-1699\(02\)00096-0](https://doi.org/10.1016/S0168-1699(02)00096-0)