

ALEXANDRE CAMILO CRUZ

**ESTIMATIVA DA DENSIDADE DE PLANTAÇÃO DE CANA DE AÇUCAR
UTILIZANDO O ESPAÇO DE COR CIE LAB EM IMAGENS DE ALTA
RESOLUÇÃO ESPACIAL PROVINDAS DE VANTs**

Sorocaba

2020

ALEXANDRE CAMILO CRUZ

**ESTIMATIVA DA DENSIDADE DE PLANTAÇÃO DE CANA DE AÇUCAR
UTILIZANDO O ESPAÇO DE COR CIE LAB EM IMAGENS DE ALTA
RESOLUÇÃO ESPACIAL PROVINDAS DE VANTs**

Dissertação apresentada como requisito para a obtenção do título de Mestre em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração Diagnóstico, Tratamento e Recuperação Ambiental

Orientador: Prof. Dr. Prof. Dr. Antônio Cesar Germano Martins

Sorocaba

2020

C957e Cruz, Alexandre Camilo
ESTIMATIVA DA DENSIDADE DE PLANTAÇÃO DE CANA
DE AÇUCAR UTILIZANDO O ESPAÇO DE COR CIE LAB EM
IMAGENS DE ALTA RESOLUÇÃO ESPACIAL PROVINDAS DE
VANTS / Alexandre Camilo Cruz. -- Sorocaba, 2020
63 p.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),
Instituto de Ciência e Tecnologia, Sorocaba
Orientador: Antônio Cesar Germano Martins

1. Processamento de imagens. 2. VANT. 3. Sensoriamento Remoto.
4. Agricultura de precisão. 5. CIE Lab. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de
Ciência e Tecnologia, Sorocaba. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Sorocaba

CERTIFICADO DE APROVAÇÃO


TÍTULO DA DISSERTAÇÃO: ESTIMATIVA DA DENSIDADE DE PLANTAÇÃO DE CANA DE AÇUCAR UTILIZANDO O ESPAÇO DE COR CIE LAB EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL PROVINDAS DE VANTS

AUTOR: ALEXANDRE CAMILO CRUZ

ORIENTADOR: ANTONIO CESAR GERMANO MARTINS

Aprovado como parte das exigências para obtenção do Título de Mestre em CIÊNCIAS AMBIENTAIS, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:


Prof. Dr. ANTONIO CESAR GERMANO MARTINS
Departamento de Engenharia Ambiental / Instituto de Ciência e Tecnologia, Câmpus de Sorocaba, Unesp


Prof. Dr. DARLLAN COELINS DA CUNHA E SILVA
Departamento de Engenharia de Pesca / Unesp - Câmpus de Registro


Prof. Dr. WALDEMAR BONVÉNTI JÚNIOR
Sistemas Biomédicos / FATEC/Sorocaba

Sorocaba, 21 de agosto de 2020

DEDICATÓRIA

À Deus por ter me dado a possibilidade ter saúde e condições para contribuir com esta pesquisa;

À minha esposa, Thieme, pela paciência, companheirismo e compreensão.

Ao meu irmão, Flávio, por ser exemplo de dedicação e perseverança.

À minha mãe Laura, pelo incentivo aos estudos e por ser um exemplo a mim e a todos que a cercam.

Ao meu pai Odair, in memoriam, por ter sido exemplo e ter me dado as melhores condições de chegar aqui hoje.

AGRADECIMENTOS

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, na pessoa do diretor do Instituto de Ciência e Tecnologia, Campus Sorocaba, Prof. Dr. Alexandre da Silva Simões;

Ao Programa de Pós-graduação em Ciências Ambientais na pessoa do coordenador Prof. Dr. José Arnaldo Frutuoso Roveda;

Aos docentes do Programa de Pós-graduação em Ciências Ambientais;

Ao Prof. Dr. Antônio Cesar Germano Martins, pela orientação, amizade e dedicação.

RESUMO

Esta pesquisa teve o objetivo de encontrar uma relação de densidade de plantio de cana de açúcar com o resultado de aplicação de índices de vegetação, utilizando as três bandas do visível, o RGB. A metodologia adotada foi a de segmentar a imagem original em cana mais densa e cana menos densa, além de outras classes fora do objeto de pesquisa, de forma automática, utilizando o software MatLab. Foram utilizadas imagens aéreas de alta resolução espacial capturadas por VANT e desenvolvida uma metodologia para transformação do espaço de cor RGB para o CIE Lab. Em cada um dos canais resultantes L, a e b foi aplicado o método de segmentação automática desenvolvido por Otsu. Estes resultados foram comparados com 10 índices de vegetação. Os resultados alcançados apresentam boa relação de valor de pixels que representam cana de açúcar com o canal a do espaço de cor CIE Lab utilizando máscara de convolução para quantificar a densidade de cana-de-açúcar.

Palavras-chave: Processamento de imagens. Agricultura de precisão. Sensoriamento remoto. CIE Lab. VANT. Cana-de-açúcar.

ABSTRACT

This research aimed to find a relation of density of planting of sugar cane with the result of application of vegetation indexes, using the three bands of the visible, the RGB. The methodology adopted was to segment the original image between denser and less dense sugarcane, in addition to other classes outside the object of research, automatically, using the MatLab software. Aerial images of high spatial resolution were used, captured by UAV and developed a methodology for transforming the RGB color space for the CIE Lab. In each of the resulting channels L, a and b, the automatic segmentation method developed by Otsu was applied. These results were compared with 10 vegetation indexes. The results achieved have a good value ratio of pixels representing sugar cane with channel a of the CIE Lab color space using a convolution mask to quantify the density of sugar cane.

Key-words: Image processing. Precision agriculture. Remote sensing. CIE Lab. UAV. Sugar cane

LISTA DE ILUSTRAÇÕES

Figura 1 – Espectro eletromagnético	20
Figura 2 - Imagem de 16 bits de um padrão de calibração de densidade e o histograma com (a) 256 canais; (b) 512 canais; (c) 1024 canais	22
Figura 3 – Modelo de cor Lab	24
Figura 4 – Mapa dos municípios da região do triângulo mineiro representando a localização da captura das imagens utilizadas neste trabalho	30
Figura 5 - Fotos aéreas obtidas pelo VANT. (a) Imagem 1 com cana mais densa em quase toda área e pouca quantidade de cana menos densa, (b) Imagem 2 com cana mais densa e menos densa em proporções similares, (c) Imagem 3 com cana mais densa e mato competição	32
Figura 6 - Ilustração do procedimento de convolução de uma máscara de pesos sobre uma imagem digital	35
Figura 7 - Representação matricial de uma imagem digital original à esquerda, a máscara de convolução ao centro, e a matriz resultante à direita. Abaixo, as operações matemáticas para ilustrar o valor final da três pixels na matriz resultante, o pixel azul de valor 137, o pixel amarelo de valor 151 e o pixel laranja de valor 51.....	36
Figura 8 – (a) Imagem 1, (b) canal L, (c) canal a (d) canal b	37
Figura 9 – (a) Imagem 2, (b) canal L, (c) canal a (d) canal b	38
Figura 10 – (a) Imagem 3, (b) canal L, (c) canal a (d) canal b.....	38
Figura 11 – Histogramas de cada um dos canais Lab, respectivamente, de (a) Imagem 1, (b) Imagem 2 e (c) Imagem 2.....	39
Figura 12 – Imagens segmentadas pelo limiar de Otsu de cada um dos canais Lab, respectivamente de (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3.....	40
Figura 13 – Resultado da segmentação pelos canais Lab, respectivamente, da Imagem 1.....	41
Figura 14 – (a) Imagem original de uma região de plantação de cana-de-açúcar da Imagem 1, (b) resultado da segmentação usando o canal a e (c) resultado da da segmentação usando o canal b.....	41
Figura 15 – Estimativas de densidade de pés-de-cana para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3.....	41
Figura 16- Resultado da aplicação do índice ExR para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	42

Figura 17- Resultado da aplicação do índice NDI para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	43
Figura 18- Resultado da aplicação do índice ExG para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	44
Figura 19- Resultado da aplicação do índice CIVE para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	45
Figura 20- Resultado da aplicação do índice CIVE para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	46
Figura 21- Resultado da aplicação do índice NGRDI para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	48
Figura 22- Resultado da aplicação do índice VEG para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	49
Figura 23- Resultado da aplicação do índice COM1 para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	50
Figura 24- Resultado da aplicação do índice MExG para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	51
Figura 25- Resultado da aplicação do índice COM2 para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.....	52
Figura 26 – Região da Imagem 1 a ser usada para a comparação dos índices, mostrando com detalhe as características de densidade de cana de açúcar.....	53
Figura 27- Resultado da imagem transformada pelo índice ExR e segmentada pelo método de Otsu.....	54
Figura 28- Resultado da imagem transformada pelo índice NDI e segmentada pelo método de Otsu.....	54
Figura 29- Resultado da imagem transformada pelo índice ExG e segmentada pelo método de Otsu.....	55
Figura 30- Resultado da imagem transformada pelo índice MExG e segmentada pelo método de Otsu.....	55
Figura 31- Segmentação da cana mais densa utilizando o resultado do método de Otsu como máscara para a imagem original e (a) índice MExG e (b) canal a do modelo Lab.....	56

Figura 32 – Parte da Imagem 1 com a presença das classe carreador, cana mais densa e cana menos densa.....	57
Figura 33 – Segmentação da cana mais densa presente na Figura 33 usando: (a) o canal a do modelo Lab e (b) o índice MExG.....	57
Figura 34- Parte da Imagem 3 com as classes cana mais densa, cana menos densa e mato-competição.....	58
Figura 35 –Segmentação da cana mais densa presente na Figura 35 usando: (a) o canal a do modelo Lab e (b) o índice MExG.....	58

LISTA DE QUADROS

Quadro1 – Informações das 3 imagens utilizadas no projeto de pesquisa, relacionadas à localização, resolução espacial e informações de configuração do sensor.....	33
Quadro 02 – Informações das 3 imagens utilizadas no projeto de pesquisa, relacionadas ao formato do arquivo, configurações da câmera e detalhes da captura	34

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Contextualização.....	13
1.2	Objetivos.....	15
1.2.1	Objetivo principal.....	15
1.2.2	Objetivos específicos.....	16
2	REVISÃO DA LITERATURA.....	17
2.1	Agricultura de precisão.....	17
2.2	Sensoriamento remoto.....	18
2.3	VANT – Veículo Aéreo Não Tripulado.....	19
2.4	Modelo de cor RGB	20
2.5	Processamento digital de imagens.....	21
2.6	O Espaço de Cor Lab.....	23
2.7	Revisão sobre índices como descritores	24
2.7.1	Normalised Difference Index (NDI).....	25
2.7.2	Excess Green Index (ExG).....	25
2.7.3	Excess Red Index (ExR).....	26
2.7.4	Colour Index of Vegetation Extraction (CIVE).....	26
2.7.5	Excess Green minus Excess Red Index (ExGR).....	27
2.7.6	Normalised Green–Red Difference Index (NGRDI).....	27
2.7.7	Vegetative Index (VEG).....	28
2.7.8	Combined Indices 1 (COM1).....	28
2.7.9	Modified Excess Green Index (MExG).....	28
2.7.10	Combined Indices 2 (COM2).....	29
3	MATERIAIS E MÉTODOS.....	30
3.1	Localização de Captura das Imagens.....	30
3.2	Avaliação da densidade de cana.....	34
4	RESULTADOS.....	37

4.1	Análise dos canais do modelo Lab.....	37
4.2	Comparação dos índices.....	42
4.2.1	Índice ExR.....	42
4.2.2	Índice NDI.....	43
4.2.3	Índice ExG.....	44
4.2.4	Índice CIVE.....	45
4.2.5	Índice ExGR.....	46
4.2.6	Índice NGRDI.....	47
4.2.7	Índice VEG.....	48
4.2.8	Índice COM1.....	49
4.2.9	Índice MExG.....	50
4.2.10	Índice COM2.....	51
4.3	Comparativo entre os índices.....	52
4.3.1	Segmentação da imagem transformada pelo índice ExR.....	54
4.3.2	Segmentação da imagem transformada pelo índice NDI.....	54
4.3.3	Segmentação da imagem transformada pelo índice ExG	55
4.3.4	Segmentação da imagem transformada pelo índice MExG	55
4.4	Comparando a segmentação da imagem transformada pelo índice MExG e pelo canal a do modelo Lab.....	56
5	CONSIDERAÇÕES FINAIS	59
	REFERÊNCIAS.....	60

1 INTRODUÇÃO

O cultivo da cana de açúcar, no Brasil vem, há bastante tempo, sendo tema de estudos e pesquisas de diversas áreas de conhecimento, em especial, na agricultura de precisão.

1.1 Contextualização

A cana-de-açúcar e seus derivados, etanol e açúcar, têm ganhado cada vez mais destaque na produção agrícola, na exportação e no abastecimento do mercado interno e externo. Atualmente, o Brasil é um dos maiores produtores destas *commodities* no mundo.

Segundo relatório da CONAB (Companhia Nacional de Abastecimento):

O Brasil, na condição de maior produtor mundial de cana-de-açúcar, projeta-se para o segmento de crescente relevância para o agronegócio brasileiro. O aumento da demanda mundial por etanol, aliado às grandes áreas cultiváveis e condições climáticas favoráveis à cana-de-açúcar, tornam o Brasil um participante na comercialização mundial com elevada competitividade.(CONAB, 2019, p.10)

No Brasil, levantamentos da CONAB apontaram para uma pequena elevação na produção de açúcar de 2020 da ordem de 3,8% em relação à safra passada, atingindo 30,14 milhões de toneladas, contra 29,04 milhões, produzidas na temporada 2018/19, fruto do ATR (Açúcar Total Recuperável) destinado à produção de açúcar permanecer praticamente idêntico ao verificado na safra passada, 35,3%.

As exportações brasileiras de açúcar seguem dando sinais de aquecimento. Em abril de 2020, o país enviou 1,55 milhão de toneladas para além de suas fronteiras, um crescimento de 27,5% ante 1,22 milhão de toneladas vistas no mesmo mês de 2019. Na comparação com março, o aumento foi de 9,7%. No acumulado de 2020, as exportações chegam a 5,86 milhões de toneladas, 31,4% a mais que as 4,46 milhões registradas de janeiro a abril do ano passado. Esses dados foram divulgados pela Secretaria de Comércio Exterior (Secex), do Ministério da Economia. (Fonte: Novacana, matéria publicada em 11 de maio 2020 - 08:57).

No caso do etanol têm-se observado um aumento na produção nas últimas duas décadas, impulsionado, principalmente, pelo aumento interno do seu uso na tentativa de se diminuir a dependência de combustíveis fósseis e mitigar os efeitos dos gases causadores do efeito estufa (RUDORFF, 2010).

O monitoramento e o gerenciamento das plantações de cana-de-açúcar são essenciais para avaliar a sustentabilidade da produção de açúcar e de etanol.

O diagnóstico e o levantamento in situ de falhas na cultura causadas por fatores diversos são atividades onerosas e nem sempre tecnicamente viáveis. Uma estimativa precisa do potencial de danos de uma lavoura requer o deslocamento de equipes em campo, e o conseqüente gasto desta operação, muitas vezes ineficaz e imprecisa.

Assim, quantificar as perdas relacionadas a falhas na cultura e os altos custos das análises laboratoriais de um grande número de amostras de solo, coletadas ao longo de áreas extensas de plantio, envolve o desenvolvimento de métodos mais efetivos para detectar e quantificar os locais específicos de sua ocorrência para uma intervenção localizada.

O uso das tecnologias na era das transformações digitais tem levado a sociedade a mudanças comportamentais significativas no seu dia-a-dia, Essas mudanças têm provocado novas formas de sociabilidade e conseqüentemente mudanças também nas organizações.

Não só o homem urbano vive essa mudança, mas ela também tem reflexo na vida rural.

No caso específico do Brasil, um país que nos últimos tempos se tornou a principal potência agrícola do mundo, as tecnologias de telecomunicação, inteligência artificial, reconhecimento de padrões e de monitoramento e controle de grande parte da cadeia produtiva rural já estão presentes nas grandes companhias agrícolas, tornando-se uma necessidade urgente para todas as propriedades rurais produtivas no país.

Na chamada agricultura de precisão procura-se aplicar o conjunto das tecnologias listadas no parágrafo anterior de forma a tornar o agronegócio mais produtivo e competitivo auxiliando o produtor rural a identificar estratégias a serem adotadas para aumentar o gerenciamento da agricultura, aumentando a rentabilidade das colheitas e a competitividade.

Neste contexto, pelo seu caráter sinóptico e repetitivo, o Sensoriamento Remoto tornou-se ferramenta importante no monitoramento agrícola, principalmente por permitir o acompanhamento da cultura ao longo do seu ciclo de desenvolvimento, viabilizar estimativas de safra e a determinação tanto de novas áreas de cultivo quanto da produtividade agrícola (RUDORFF, 2010).

Nos últimos anos, uma das principais tecnologias introduzidas na área do agronegócio brasileiro foram os VANTs (Veículos Aéreos Não Tripulados) que permitem o monitoramento de grandes ou pequenas áreas através do imageamento aéreo com rapidez e baixo custo, tendo ganhado popularidade e gerado demandas de análises agrícolas, relacionadas à produtividade, fitossanidade e monitoramento de riscos ambientais.

Um importante desafio do processo que envolve a cadeia de captura, processamento e análise destas imagens provindas dos VANTs é o fato de existir uma grande massa de dados a ser tratada e que gerem informações relevantes para a tomada de decisão pelo produtor rural.

No caso do agronegócio ligado a cana-de-açúcar, têm-se buscado utilizar os VANTs desde o advento desta tecnologia no Brasil em meados de 2010. Entretanto, ainda existe a necessidade de se criar processos que garantam a confiabilidade e rapidez para análise da densidade de cana que levem a ações que aumentem a produtividade.

Neste sentido, este estudo visa contribuir com a avaliação da eficácia da atribuição de valores de densidade de cana-de-açúcar utilizando índices obtidos pelas combinações de canais de cor calculados a partir de imagens aéreas de VANTs.

Desta forma, é explorado o uso do modelo de cor *Lab* para realçar a representação da classe cana-de-açúcar que permita a estimativa da densidade da plantação saudável, comparando-se os resultados com o uso de índices consolidados na literatura que usam as características de absorção associadas com constituintes bioquímicos para avaliar as culturas em estudo (HAMUDA, GLAVIN e JONES, 2016).

Esta dissertação foi dividida em 5 capítulos. No primeiro capítulo introdutório, descreve-se uma contextualização do cenário da cana de açúcar no Brasil e a transformação digital no campo além de listar os objetivos deste estudo. No segundo capítulo é feita a revisão da Literatura com os temas abordados nesta pesquisa. O terceiro capítulo aborda a metodologia empregada nesta pesquisa. No quarto capítulo tratou-se sobre os resultados obtidos e as discussões acerca dos resultados. No quinto capítulo são apresentadas as considerações finais referentes à pesquisa realizada.

1.2 Objetivos

A seguir estão descritos os objetivos a serem atingidos neste projeto de pesquisa.

1.2.1 Objetivo Principal

Esta pesquisa visa a aplicação do processamento digital e o uso do modelo de cor *Lab* para segmentar regiões de uma plantação de cana-de-açúcar visando a estimativa automática da densidade de plantio a partir de imagens aéreas de alta resolução espacial capturadas com VANTs.

1.2.2 Objetivos específicos

- Utilizar o modelo de cor *Lab* para analisar as classes existentes em plantações de cana-de açúcar.
- Avaliar a adequação do uso do método de Otsu para a separação das classes.
- Comparar os resultados dos índices gerados a partir do modelo *Lab* com os da literatura.
- Propor um método de estimativa da densidade de cana-açúcar plantada.

2 REVISÃO DA LITERATURA

Abaixo dissertaremos sobre alguns estudos das imagens capturadas por VANTs.

2.1 Agricultura de precisão

Tem-se difundindo progressivamente o conhecimento de que existe uma variabilidade nas áreas de produção agrícola que pode ser devida às variações do relevo, solos, vegetação e também do histórico de uso do solo. O conhecimento dessa variabilidade e da sua qualidade é útil para o controle e acompanhamento de qualquer cultura, sejam aquelas cultivadas em pequenas áreas como aquelas que ocupam grandes extensões de terra.

O procedimento para isso é bem simples, basta que o produtor ou o técnico inicie um trabalho de observação, medida e registro da variabilidade, cujo resultado, por ser individualizado, diverge de produção para produção. Estas particularidades fazem com que as ações de manejo variem em cada região, de acordo com suas potencialidades e necessidades. (BERNARDI et. al., 2014)

Com a constante evolução do setor canavieiro, observa-se que o produtor passa a ter preocupação crescente com o meio ambiente, forçado pela necessidade de comprovar a viabilidade do etanol como fonte de energia alternativa econômica e ambientalmente.

Neste cenário, surge o interesse crescente pela agricultura de precisão que, de uma forma geral, tem por objetivo otimizar os usos de insumos no setor, focando no aumento de produtividade por área e a diminuição de impactos ambientais.

Dessa forma, a adoção da tecnologia de agricultura de precisão não pode ser realizada adequadamente sem o domínio dos conhecimentos básicos necessários para se coletarem as informações importantes sobre as variações locais do campo, além da interpretação correta dos resultados.

O grande desafio da agricultura de precisão está, primeiramente na medição de parâmetros de solo, planta e clima com suficiente frequência espacial e temporal nas áreas de produção e, em segundo lugar, na determinação da correlação desses parâmetros com a produtividade (GREGO et. al., 2014).

A agricultura de precisão considera exatamente esse cenário: a presença, distribuição e intensidade de uma condição específica que causa redução no rendimento da cultura agrícola que devem ser identificadas e receber tratamento diferenciado (HILLNHUTTER et al, 2011).

Nesse contexto, o monitoramento remoto da vegetação em condições de estresse é particularmente importante, uma vez que os custos relacionados com a intensa amostragem ou manejo agrícola indiscriminado para toda área de cultivo podem ser minimizados pelo mapeamento prévio das áreas que apresentam falhas.

Assim, o uso direcionado como ferramenta de planejamento, controle e análise de dados agrícolas, prevê o monitoramento das variações espaciais e temporais dos fatores que limitam a produção, orientando no processo de tomada de decisão, na aplicação de insumos em áreas específicas e no manejo diferenciado das culturas no campo de produção (MARTINS et al., 2017).

2.2 Sensoriamento remoto

O sensoriamento remoto (SR) se caracteriza pela obtenção de informações de um objeto sem existir contato físico com o mesmo, e muitas vezes a longas distâncias.

A radiometria espectral é uma das mais importantes áreas do SR, pois ela identifica a intensidade com que cada material, seja um tipo de solo, de rocha ou de vegetação, reflete a radiação eletromagnética em diferentes comprimentos de onda do espectro (BRANDAO et al., 2008). Assim, dados da refletância têm sido associados às características das plantas como o índice da área foliar, a biomassa ou a fração radiativa interceptada fotossinteticamente.

As primeiras medições por SR foram realizadas através de câmeras acopladas em aeronaves, balões, pipas, foguetes e até pássaros. Atualmente, imagens de sensores remotos podem ser obtidas a partir de diversas plataformas, como satélites, aeronaves, veículos aéreos não tripulados (VANTs), máquinas agrícolas auto propelidas, etc.

Várias aplicações podem ser abordadas através de SR, dentre elas, se destacam: a estimativa da biomassa e produtividade da cultura; o monitoramento de estresse hídrico e do vigor nas plantas e a avaliação do estágio fenológico (BRANDAO, 2009).

Uma das primeiras aplicações dos dados obtidos remotamente tem sido a detecção de diferenças na refletância, relacionadas a densidade da cobertura vegetal.

Na agricultura, as propriedades da refletância em cada faixa do espectro eletromagnético podem ser mais bem avaliadas através de combinações matemáticas de diferentes bandas espectrais (ATZBERGER, 2013).

Atualmente, uma série de novos sensores multiespectrais instalados em plataformas espaciais aerotransportadas incluem bandas espectrais específicas e apropriadas para monitorar atividades agrícolas. As Aeronaves Remotamente Pilotadas (ARPs), (Em inglês RPAs sigla

de *Remotely Piloted Aircraft System*), é o termo técnico e padronizado internacionalmente pela OACI (Organização da Aviação Civil Internacional) para se referir aos sistemas aéreos pilotados remotamente, utilizadas com propósitos não recreativos. ARPs apresentam-se como uma ferramenta promissora em aplicações no setor agrícola e em missões de reconhecimento, principalmente pela redução de custo e do tamanho dos equipamentos colocados a bordo (OUMAR e MUTANGA, 2014).

Neste estudo, será utilizada uma ARP categorizada como VANT, para captura de imagens aéreas. VANT é a sigla de Veículo Aéreo Não Tripulado (tradução do termo UAV – Unmanned Aerial Vehicle) e é o termo utilizado para se referir a todo e qualquer equipamento que acesse o espaço aéreo sem que haja a presença de um ser humano a bordo.

Além do mais, a alternativa de solução, baseada em imagens tomadas de plataformas aéreas, constitui uma solução que pode ser viabilizada, caso seja baseada na integração de diferentes sensores instalados nos VANTs, que permitem maior flexibilidade na tomada de imagens, principalmente no caso do monitoramento de culturas agrícolas, sendo uma excelente ferramenta para a Agricultura de Precisão.

2.3 VANT – Veículo Aéreo Não Tripulado

Os VANTs são aeronaves autônomas remotamente controladas que possuem embarcados, dentre outros componentes, os sensores que permitem a aquisição de imagens aéreas com alta resolução espacial, com baixo custo, de maneira rápida, confiável e precisa.

A utilização dos VANTs no Brasil foi regulamentada recentemente pela ANAC (Agência Nacional de Aviação Civil) em maio de 2017 e dentre várias soluções que o mesmo permite, o mapeamento de uso e ocupação do solo de áreas rurais é uma atividade muito visada para finalidades de monitoramento ambiental. Mas o grande e principal diferencial das imagens adquiridas pelos VANTs é à resolução espacial. Como exemplo, pode-se citar a possibilidade de capturar uma imagem de uma área de 50 hectares (500 mil m²) com pixel de 5 cm em um único voo de 40 minutos.

Com a facilidade de aquisição de imagens pelos VANTs é possível se obter uma grande quantidade de dados brutos, ou seja, sem tratamento, tornando-se necessário o desenvolvimento de processos automáticos para a geração de produtos de interesse.

Assim, fica a cargo do especialista ou técnico as análises destes produtos que irão gerar relatórios qualitativos e quantitativos. Dois exemplos deste processo são a localização e a quantificação de falhas em plantio de cana de açúcar.


2.4 Modelo de cor RGB

Uma imagem digital pode ser definida como uma função bidimensional $f(x, y)$, em que x e y são coordenadas de valores inteiros em um plano e f é a intensidade ou nível de cinza em (x, y) . Assim, uma imagem digital é composta de um número finito de elementos chamados de pixels, cada um com localização e valor específico (GONZALEZ; WOODS, 1992).

O campo do processamento digital de imagens se refere à manipulação computacional dos pixels de forma a se obter informações contidas nestas imagens.

A cor presente em uma imagem se refere ao comprimento de onda da luz refletida por uma superfície e capturada por um sensor. A Figura 1 apresenta uma representação do espectro eletromagnético com destaque para a região do visível.

Para se representar uma imagem digital colorida são usadas representações baseadas em três canais sendo o modelo RGB um dos mais conhecidos, utilizando três componentes: R (*Red* - vermelho), G (*Green* - verde) e B (*Blue* - azul). No RGB, a informação da cor é obtida pela apresentação dos três canais.



Fonte: Simões, 2014

A CIE (Commission Internationale de l'Éclairage ou Comissão Internacional de Iluminação) padronizou os comprimentos de onda das cores primárias RGB da seguinte forma: azul=435,8 nm, verde=546,1 nm e vermelho = 700 nm.

2.5 Processamento digital de imagens

Uma imagem digital pode ser criada a partir de softwares de desenho ou adquirida por meio de algum dispositivo. A maneira como esta imagem é armazenada no computador define o formato do arquivo. Os formatos mais comuns são: bmp (bitmap), gif, png e jpg. (Martins A. C. G., 2020).

A área de processamento de imagens se refere à manipulação destes pixels visando à melhoria na apresentação da imagem, o realce ou eliminação de certas características e a extração de informações [Gonzales 2000, Crane 1997].

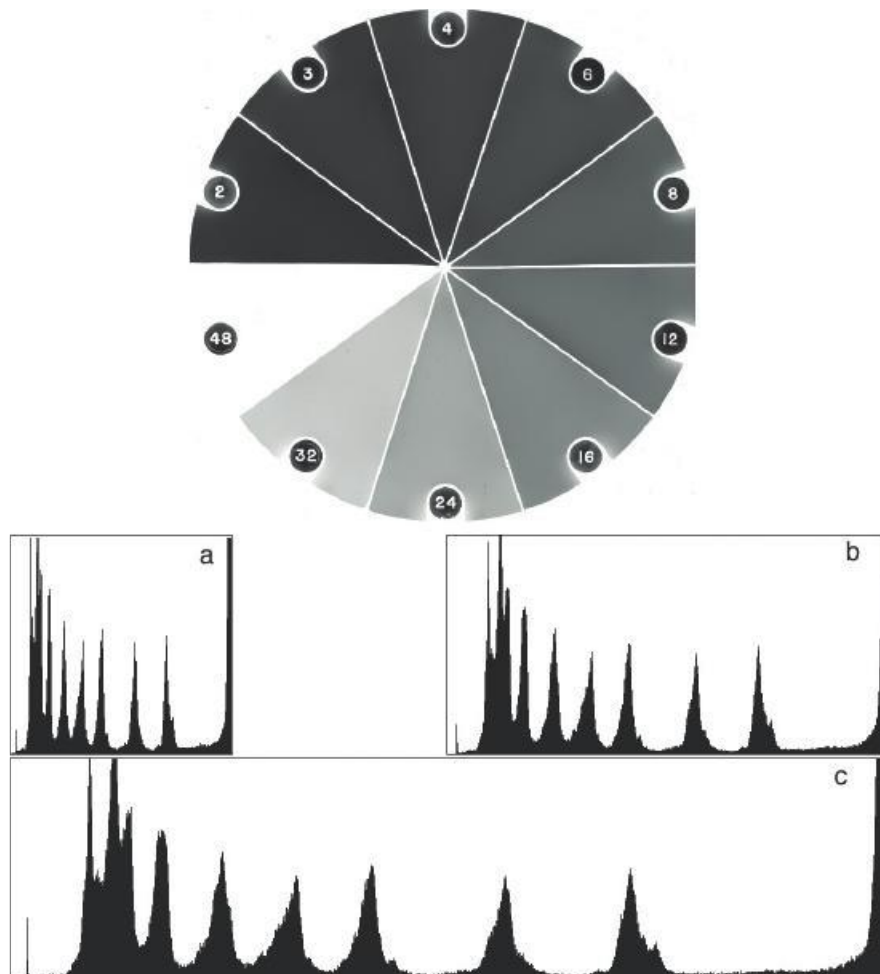
Segundo Martins (2018) a separação dos pixels relativos a cada objeto, ou região, é uma etapa fundamental para o sucesso do processo de análise da imagem. Embora o ser humano possa facilmente identificar regiões com as mesmas características ou objetos presentes em uma cena, na aquisição da imagem, o pré-processamento, a segmentação e o reconhecimento dos objetos e regiões em uma imagem, para se realizar essas tarefas com um computador, deve-se implementar algoritmos que analisem as características individuais ou da distribuição da população de pixels.

Uma imagem só pode ser processada em um computador se a mesma estiver no formato digital, ou seja, ela deve ser formada por pixels espaçados de uma distância d . Para se realizar a digitalização de imagens são utilizados dispositivos que convertem a radiação incidente em unidades de informações.

Dada uma cena ou uma imagem contínua, o processo de amostragem permite a criação de uma imagem digital representando esta imagem por uma matriz bidimensional de $N \times M$ pixels. Quanto maiores os valores de N e M usados, melhor será esta representação. (Martins A. C. G., 2020).

Segundo Ross (2011), o ato de selecionar objetos ou recursos em uma cena ou imagem é um pré-requisito importante para a maioria dos tipos de medição ou análise. Para isto, pode-se usar o histograma de uma imagem que apresenta a distribuições dos tons de cinza conforme mostrado na Figura 2.

Figura 2 - Imagem de 16 bits de um padrão de calibração de densidade e o histograma com (a) 256 canais; (b) 512 canais; (c) 1024 canais.



Fonte: ROSS, 2011.

Utilizando-se o histograma, uma maneira de se obter a seleção de regiões de interesse em imagens é definir uma faixa de valores de intensidade, selecionar os pixels dentro desse intervalo como pertencentes ao primeiro plano e rotular todos os outros pixels como fundo, resultando em uma imagem binária (de dois níveis), usando-se o preto e branco (ou às vezes outras cores) para distinguir as regiões.

A obtenção de um limiar de forma automática é conseguida utilizando-se o método de Otsu que aproxima o histograma de uma imagem por funções Gaussianas e escolhe o valor que minimiza a variância intra-classes (OTSU, 1978).

Para se segmentar uma região em uma imagem pode-se, ao invés de se utilizar diretamente os canais RGB, obter índices a partir destes (Hamuda, Glavin e Jones, 2016).

Neste contexto, o uso de modelos de cor que levem ao desacoplamento das informações da intensidade luminosa e a cor propriamente dita, permite a aplicação de processos simples de processamento da imagem que possam melhor distinguir os alvos de interesse para posterior segmentação e análise de regiões de interesse.

2.6 O Espaço de Cor *Lab*

Uma cor não é somente um fenômeno físico, mas também psicofisiológico. Sabe-se que o olho humano possui sensores (cones) capazes com respostas em torno de três comprimentos de onda (SEKULER, 1990), originando a denominação tricromatismo. De acordo com Rocha (2011):

Nós herdamos de nossos antepassados a visão tricrômica, ou seja, vemos todas as cores baseadas em apenas três: o vermelho, o azul e o verde (Rocha, 2011).

Ainda neste sentido, e segundo a CIE, cor é uma questão de percepção e subjetividade da interpretação, precisando ser expressa de forma objetiva por meio de números para garantir que o produto final esteja de acordo com suas especificações. Quando as cores são ordenadas, elas podem ser expressas em termos de tonalidade, luminosidade e saturação. Com a criação de escalas para esses atributos, pode-se expressar cores de forma precisa.


O espaço de cor *Lab* foi criado após a teoria de cores opostas, onde duas cores não podem ser verdes e vermelhas, ou amarelas e azuis ao mesmo tempo (RANGAYYAN, R.M.; ACHA, B.; SERRANO, C, 2011).

No espaço de cor *Lab*, o *L* indica a luminosidade e o *a* e *b*, são as coordenadas cromáticas.

- ***L* = Luminosidade**
- ***a* = coordenada vermelho/verde (+*a* indica vermelho e –*a* indica verde)**
- ***b* = coordenada amarelo / azul (+*b* indica amarelo e –*b* indica azul)**

A figura 3 ilustra este modelo de cor, sendo que se *L* for próximo de 100 será mais claro e o *L* chegando ao valor 0 fica próximo ao preto.

Figura 3 – Modelo de cor Lab



Fonte: Alves(2011)

Considerando-se que as folhas da cana de açúcar saudável possuem tonalidades de verde e as não saudáveis possuem tons de marrom, o espaço *Lab* é bastante apropriado para a análise de imagens agrícolas.

2.7 Revisão sobre índices como descritores

Os índices são obtidos da associação de diversos canais de cores que realçam características de regiões de interesse em imagens.

Estando disponíveis várias faixas do espectro eletromagnético, a escolha dos comprimentos de onda mais adequados está relacionada às características que se deseja avaliar (Zarco-Tejada et al.,2001).

Diferentes índices são otimizados para aplicações específicas (BRANDAO, 2009). Por exemplo, alguns índices espectrais foram propostos para capturar os processos fotoquímicos associados com a atividade da fotossíntese ou estimar o conteúdo de pigmentação da folha (clorofila) (DAUGHTRY et al., 2000; BRITO et al., 2011).

Em um artigo científico publicado em 2016, pesquisadores da Universidade Nacional da Irlanda, testaram 10 índices e combinações das bandas RGB para a segmentação e extração de plantas em imagens que representam culturas agrícolas diversas. O principal objetivo deste estudo foi o de separar plantas do fundo com a finalidade de monitorar as ervas daninhas que

competem com as culturas e acabam diminuindo a produtividade do plantio. Neste trabalho também foram apresentadas as vantagens e desvantagens de cada índice.

A seguir serão apresentados os índices avaliados por Hamuda, Glavin e Jones (2016) e que serão utilizados neste trabalho na etapa de comparação.

2.7.1 Normalised Difference Index (NDI)

O NDI foi proposto por Woebbecke et al. (1992) para distinguir material vegetal do fundo do solo em uma imagem RGB. A principal vantagem deste índice decorre da sua simplicidade de implementação computacional. Este índice também possui robustez quanto ao resultado final mesmo com imagens com grau de iluminação distintas, exceto para valores extremos. Uma desvantagem é que o índice resulta em muitos falsos positivos.

$$NDI = 128 * \left(\left(\frac{(G - R)}{(G + R)} \right) + 1 \right) \quad (1)$$

2.7.2 Excess Green Index (ExG)

Woebbecke et al. (1995) examinaram vários índices de vegetação colorida usando coordenadas cromáticas para a separação da planta verde do solo nu (resíduo de milho e resíduo de palha de trigo). Os índices de vegetação colorida que foram utilizados são:

$$ExG = 2g - r - b \quad (2)$$

onde r , g e b são coordenadas cromáticas calculadas por:

$$r = \frac{R^*}{(R^* + G^* + B^*)}, \quad g = \frac{G^*}{(R^* + G^* + B^*)}, \quad b = \frac{B^*}{(R^* + G^* + B^*)}$$

e R , G e B os valores RGB normalizados que variam de 0 a 1 e são calculados da seguinte forma:

$$R^* = \frac{R}{R_{max}}, \quad G^* = \frac{G}{G_{max}}, \quad B^* = \frac{B}{B_{max}}$$

sendo R, G e B os valores reais de pixel das imagens com base em cada canal e R_{max} , G_{max} , B_{max} considerados como 255 para uma imagem de 24 bits para representar cor (cada canal com 8 bits).

O índice ExG tem sido amplamente utilizado por apresentar um bom desempenho na separação entre plantas e os demais elementos presentes na imagem (Meyer et al., 1998; Lamm et al., 2002; Ribeiro et al., 2005; Guerrero et al., 2012).

A principal desvantagem deste índice é que não apresenta bons resultados quando a intensidade luminosa é muito alta ou muito baixa.

2.7.3 Excess Red Index (ExR)

Meyer et al. (1998) inspirados pelo fato de existirem 4% de azul, e 32% de verde, em comparação com 64% de cones vermelhos na retina do olho humano, introduziram o ExR. Este índice conseguiu separar os pixels da planta dos pixels de fundo, mas não foi tão preciso quanto o ExG. A expressão para ExR:

$$ExR = 1,3 * R - G \quad (3)$$

As principais vantagens de aplicação do índice ExG são a facilidade de cálculo, extração de pixels verdes, mesmo se baseando principalmente no componente vermelho, e a segmentação de textura do solo.

As desvantagens são a dificuldade de trabalhar com ambientes demasiadamente muito ou pouco iluminados e ser menos preciso na segmentação do que o índice ExG.

2.7.4 Colour Index of Vegetation Extraction (CIVE)

O índice CIVE foi proposto por Kataoka et al. (2003), com base em estudo realizado em soja e campos de beterraba para separar as plantas do solo visando a avaliação do estágio de crescimento da cultura. A expressão para o CIVE é a seguinte:

$$CIVE = 0,44R - 0,811G + 0,385B + 18,777 \quad (4)$$

Kataoka et al. descobriram que o CIVE tem melhor segmentação de plantas do que o baseado no infravermelho próximo (NIR), pois fornece maior ênfase das áreas verdes.

Como principais vantagens quanto à utilização deste índice, pode-se citar a rapidez para o cálculo do índice e a boa adaptabilidade a imagens obtidas ao ar livre. As desvantagens são o desempenho ruim quando a intensidade luminosa é muito alta ou muito baixa e a pouca adaptabilidade à presença de sombras.

2.7.5 Excess Green minus Excess Red Index (ExGR)

Este índice foi introduzido por Meyer et al. (2004) combinando dois outros, o ExG e o ExR, sendo aplicado para separar as plantas do solo e dos demais elementos presentes na imagem. O ExG extrai a região da planta e o ExR elimina elementos verde-vermelho (solo, caules, galhos ou pecíolos). O ExGR é definido por:

$$ExGR = ExG - ExR \quad (5)$$

As principais vantagens do ExGR são a boa adaptabilidade ao ar livre e o fato de poder executar duas tarefas simultaneamente: extrair o verde pelo ExG e eliminar o ruído de fundo pelo ExR. As desvantagens são o desempenho ruim quando a luz é muito forte ou muito baixa e o fato de segmentar os pixels da sombra como plantas.

2.7.6 Normalised Green–Red Difference Index (NGRDI)

O NGRDI foi proposto por Hunt et al. (2005) e testado em imagens digitais que foram capturadas por uma câmera digital montada na parte inferior da fuselagem de uma aeronave de diversas culturas como: milho, alfafa e soja. O NGRDI foi utilizado para superar as diferenças de configurações de exposição selecionadas pela câmera digital ao adquirir as fotografias aéreas do campo. Essas diferenças podem causar grandes diferenças nas faixas de cores com a mesma refletância. O NGRDI possui a seguinte expressão:

$$NGRDI = \frac{G-R}{G+R} \quad (6)$$

As vantagens do NGRDI são a capacidade de redução das diferenças na configuração de exposição selecionada pela câmera digital.

2.7.7 Vegetative Index (VEG)

O índice VEG foi proposto por Hague et al. (2006) para separar pixels de plantas (cereais e ervas daninhas) dos pixels do solo. O estudo foi realizado em condições de campo a céu aberto e as imagens utilizadas para os testes foram capturadas por uma câmera CCD. Para alcançar a segmentação, uma imagem RGB foi convertida em escala de cinza usando a seguinte expressão:

$$VEG = \frac{G}{R^{\alpha}B^{1-\alpha}} \quad (7)$$

onde α é um valor constante igual a 0,667. Os autores descobriram que esta transformação apresenta bom contraste entre planta e solo. Além disso, o VEG é robusto à variação de iluminação.

2.7.8 Combined Indices 1 (COM1)

Guijarro et al. (2011) selecionaram quatro índices: ExG, CIVE, ExGR e VEG e criaram um novo índice definido por:

$$COM1 = ExG + CIVE + ExGR + VEG \quad (8)$$

Segundo Hamuda et al. (2016), o índice combinado apresentou melhores resultados do que quando foram aplicadas separadamente. Este índice foi testado em campos de cevada e milho e mostrou alta confiabilidade sob várias condições de iluminação em ambientes externos.

2.7.9 Modified Excess Green Index (MExG)

O MExG foi desenvolvido por Burgos-Artizzu et al. (2011) e é definido por:

$$MExG = 1,262G - 0,884R - 0,311B \quad (9)$$

Este índice converteu com êxito a imagem colorida em escala de cinza, facilitando o processo de binarização. A discriminação entre a planta e a região do solo foi eficaz porque o método MExG se mostrou robusto às mudanças nas condições de iluminação não ideais e obteve melhores resultados que o ExG.

2.7.10 Combined Indices 2 (COM2)

Este índice foi introduzido por Guerrero et al. (2012) para a análise de plantas de milho e é bastante semelhante à COM1 ao combinar índices de cores que no caso de COM2 foram: ExG, CIVE e VEG. O ExGR foi excluído porque classificou a sombra da planta de milho como parte da planta. A contribuição de cada um dos índices selecionados é controlada por pesos que somados resultam em 1. O COM2 é definido da seguinte forma:

$$COM2 = 0,36ExG + 0,47CIVE + 0,17VEG \quad (10)$$

Após revisar estes 10 índices e suas capacidades de transformação da imagem RGB para posterior utilização na segmentação de feições de interesse em plantio de cana de açúcar, propôs-se aplicar cada um dos índices supracitados nas imagens selecionadas para testes, conforme descrito nos capítulos posteriores.

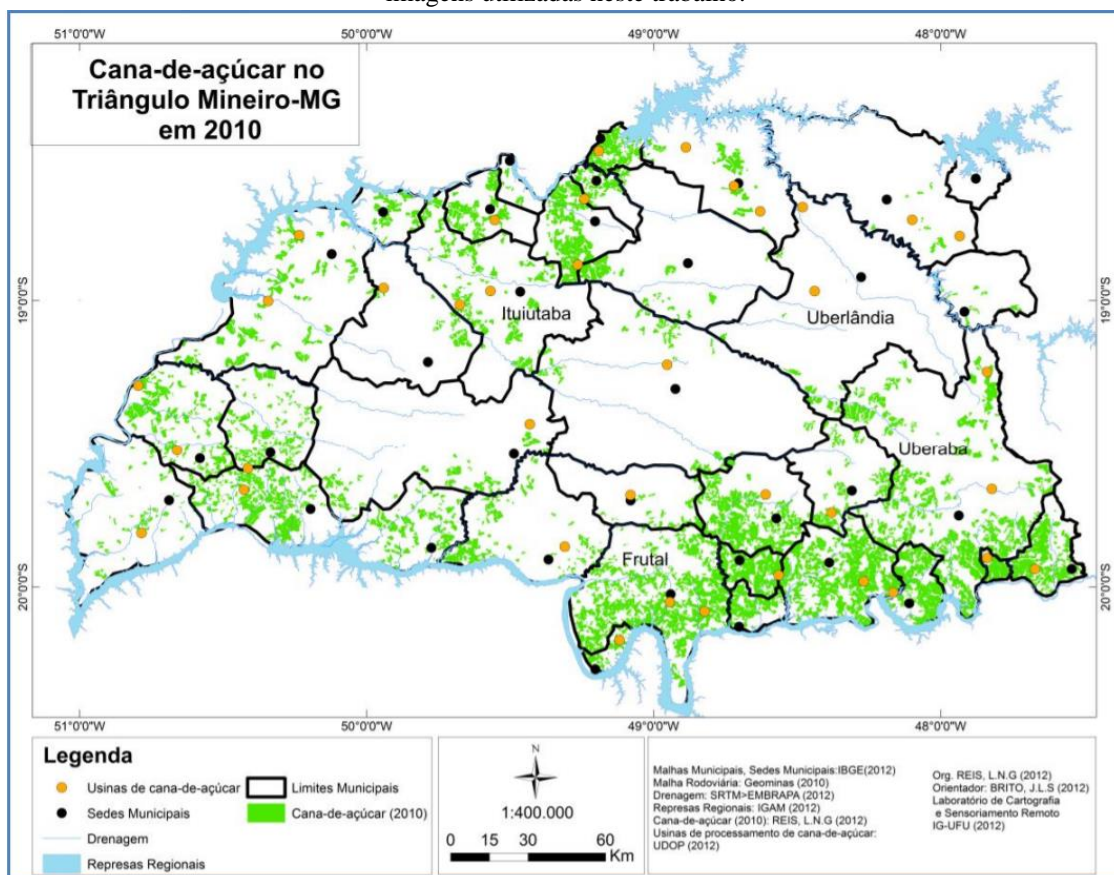
3 MATERIAIS E MÉTODOS

As imagens foram obtidas no dia 23 de junho de 2018, por volta das 14 horas (horário de Brasília) pelo Vant, do tipo multirrotor da marca DJI, modelo Phantom 4 PRO. A região escolhida foi uma área de plantio de cana em Uberlândia-MG. Foi utilizado o software Matlab para o processamento das imagens aéreas capturadas pelo Vant.

3.1 Localização de Captura das Imagens

As imagens foram obtidas em uma plantação de cana de açúcar a 61,4 km ao sul de Uberlândia-MG sentido Campo Florido-MG, tendo sido adquiridas e gentilmente cedidas pelo professor doutor George Deroco Martins da UFU (Universidade Federal de Uberlândia).

Figura 4 – Mapa dos municípios da região do triângulo mineiro representando a localização da captura das imagens utilizadas neste trabalho.



Fonte: REIS;BRITO (2010, p. 10)

Uberlândia é um município que, juntamente com Uberaba e Araguari, faz parte do Triângulo Mineiro, no Estado de Minas Gerais. Localiza-se a 537 km a oeste da capital do Estado de Minas Gerais, Belo Horizonte.

Devido ao fato de ser o segundo município mais populoso do estado, com cerca de 570 mil habitantes, ficando atrás apenas da capital, destaca-se pelo setor de serviços. Além desse, o agronegócio com a pecuária e monoculturas de café e cana-de-açúcar, se faz bastante presente na economia local.

A vegetação nativa da região é predominantemente o Cerrado, e o clima, no mês de junho, época das tomadas das imagens, costuma ter temperatura média próxima aos 20° Celsius.

O motivo de escolha desta área para a realização da pesquisa foi pelo fato de possuir grandes fazendas que arrendam suas terras para o plantio de cana de açúcar, podendo-se citar o Coruripe e a BP-BUNGE como dois grandes grupos de Usinas do mercado Sucroenergético que possuem unidades industriais na região.

Para os testes preliminares, optou-se pela utilização de fotos aéreas perpendiculares, com composição colorida (R,G,B) e com resolução espacial de 1,1 cm, sem tratamento e transformações.

Foram capturadas imagens aéreas perpendiculares de um mesmo talhão de plantio de cana de açúcar. Desta aquisição foram separadas 3 imagens para o desenvolvimento do projeto (Figura 5). Estas imagens foram escolhidas por apresentarem variações na densidade de plantação da cana-de-açúcar devido ao plantio irregular, dobramento das plantas, presença de outras espécies invasoras além da presença de solo exposto e vias de acesso.

Nas imagens da Figura 5 pode-se perceber a presença de cana de açúcar densa por quase toda sua extensão, além de falhas e plantas pisoteadas, normalmente por máquinas agrícolas, que diminuem a produtividade da safra. É importante salientar que as usinas de cana-de-açúcar dependem de números de TCH (Tonelada-Cana-Hectare) altos para que não falte cana na moagem, mantendo a indústria em ritmo constante e, conseqüentemente, aproveitando ao máximo a capacidade instalada, sem a necessidade de comprarem cana-de-açúcar no mercado.


Figura 5 - Fotos aéreas obtidas pelo VANT. (a) Imagem 1 com cana mais densa em quase toda área e pouca quantidade de cana menos densa, (b) Imagem 2 com cana mais densa e menos densa em proporções similares, (c) Imagem 3 com cana mais densa e mato competição



(a)



(b)



(c)

Fonte: UFU (Universidade Federal de Uberlândia).

O Quadro 1 traz informações mais detalhadas da localização, resolução espacial e da configuração do sensor do VANT no momento da aquisição. No Quadro 2 são apresentadas

informações relacionadas ao formato do arquivo, configurações da câmera e detalhes da captura.

Quadro1 – Informações das 3 imagens utilizadas no projeto de pesquisa, relacionadas à localização, resolução espacial e informações de configuração do sensor.

GPS information:			
Nome de identificação	Imagem 1	Imagem 2	Imagem 3
GPSVersionID	2.3.0.0	2.3.0.0	2.3.0.0
GPSLatitudeRef	S	S	S
GPSLatitude	19 21 47.9025 (19.363306)	19 21 46.615299 (19.362949)	19 22 11.8791 (19.369966)
GPSLongitudeRef	W	W	W
GPSLongitude	48 23 20.2236 (48.388951)	48 23 21.415701 (48.389282)	48 23 35.872898 (48.393298)
GPSAltitudeRef	Sea level	Sea level	Sea level
GPSAltitude	853.14 m	852.74 m	863.75 m
Thumbnail:			
Compression	6 (JPG)	6 (JPG)	6 (JPG)
XResolution	72	72	72
YResolution	72	72	72
ResolutionUnit	Inch	Inch	Inch
JpegIFOffset	3060	3060	3060
JpegIFByteCount	10228	10216	10463
SceneCaptureType	Standard	Standard	Standard
GainControl	None	None	None
Contrast	Normal	Normal	Normal
Saturation	Normal	Normal	Normal

Fonte: Informações retiradas da fonte “metadados” das três imagens capturadas pelo VANT

Para a implementação do processamento de imagens, optou-se por utilizar, como ambiente de trabalho, o software MatLab por disponibilizar diversas ferramentas, ser de amplo uso e possuir fóruns de discussão.

Quadro 02 – Informações das 3 imagens utilizadas no projeto de pesquisa, relacionadas ao formato do arquivo, configurações da câmera e detalhes da captura.

Nome de identificação	Imagem 1	Imagem 2	Imagem 3
Filename	DJI_0443.JPG	DJI_0445.JPG	DJI_0679.JPG
Make	DJI	DJI	DJI
Model	FC6310	FC6310	FC6310
Orientation	Top left	Top left	Top left
XResolution	72	72	72
YResolution	72	72	72
ResolutionUnit	Inch	Inch	Inch
Software	v01.05.1577	v01.05.1577	v01.05.1577
DateTime	2018:06:23 14:09:54	2018:06:23 14:10:00	2018:06:23 14:54:01
YCbCrPositioning	Centered	Centered	Centered
ExifOffset	182	182	182
ExposureTime	1/160 seconds	1/160 seconds	1/120.0 seconds
FNumber	4.50	4.50	4.00
ISOSpeedRatings	100	100	100
ExifVersion	230	230	230
DateTimeOriginal	2018:06:23 14:09:54	2018:06:23 14:09:59	2018:06:23 14:54:00
ComponentsConfiguration	CrCb	CrCb	CrCb
CompressedBitsPerPixel	3.25 (bits/pixel)	3.27 (bits/pixel)	3.37 (bits/pixel)
ShutterSpeedValue	1/160 seconds	1/160 seconds	1/125 seconds
ApertureValue	F 4.48	F 4.48	F 4.00
ExposureBiasValue	0.00	0.00	0.00
MaxApertureValue	F 2.80	F 2.80	F 2.80
MeteringMode	Center weighted verage	Center weighted verage	Center weighted verage
LightSource	Auto	Auto	Auto
FocalLength	8.80 mm	8.80 mm	8.80 mm
FlashPixVersion	10	10	10
ColorSpace	sRGB	sRGB	sRGB
ExifImageWidth	4864	4864	4864
ExifImageHeight	3648	3648	3648
InteroperabilityOffset	656	656	656
FileSource	DSC	DSC	DSC
ExposureMode	Auto	Auto	Auto
White Balance	Manual	Manual	Manual
DigitalZoomRatio	0.00/0.00 x	0.00/0.00 x	0.00/0.00 x
FocalLengthIn35mmFilm	24 mm	24 mm	24 mm

Fonte: Informações retiradas da fonte “metadados” das três imagens capturadas pelo VANT

3.2 Avaliação da densidade de cana

A partir das imagens originais foram calculados os índices avaliados por Hamuda, Glavin e Jones (2016). Em seguida as imagens foram transformadas para o modelo de cor *Lab*

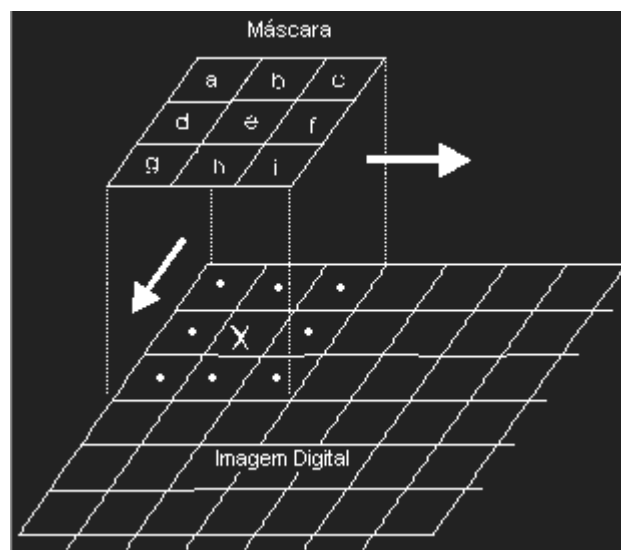
e feitas avaliações do uso dos canais a e b como índices para a separação da cana-de-açúcar dos demais elementos presentes nas imagens. Considerando que os canais a e b podem ter valores negativos e que foram utilizadas funções de processamento que trabalham apenas com valores positivos, como por exemplo o de construção do histograma da imagem, os canais a e b foram linearmente mapeados para o intervalo $[0, 255]$.

As imagens resultantes da aplicação dos índices passaram pelo processo de limiarização automático utilizando-se o método de Otsu [OTSU, 1978]. O método foi aplicado através de uma função já existente na biblioteca do software Matlab, que transforma a imagem original de entrada composta pelos três canais do espaço de cor R, G e B em três canais do espaço de cor L , a e b .

Após a separação das imagens em duas classes, cana-de-açúcar mais densa e demais elementos, obteve-se a estimativa da densidade de cana pela aplicação de uma máscara de tamanho de um pé-de-cana de açúcar isolado (100×100 pixels no caso das imagens utilizadas) com todos os elementos tendo valor 1. O resultado da convolução da máscara com a imagem binarizada de cana-de-açúcar representa a densidade da cana.

A operação de convolução realiza a varredura sobre toda a imagem original, modificando seus valores de acordo com os valores dos pixels e os pesos da máscara (ver Figura 6). A máscara utilizada é também uma imagem, em geral quadrada, menor que a imagem original. Desta forma, os valores dos elementos da máscara são utilizados como pesos a serem aplicados sobre os pixels da imagem original.

Figura 6 - Ilustração do procedimento de convolução de uma máscara de pesos sobre uma imagem digital



Na ilustração da figura 6, a máscara é aplicada sobre a área equivalente da imagem original e o resultado será a atribuição de um novo valor para o pixel central (marcado com X). Os pesos das máscaras podem ser valores positivos, negativos ou zero.

A seguir na figura 07, pode-se verificar o detalhamento de um procedimento de “varredura” de uma máscara de convolução pixel a pixel.

Figura 7 – Representação matricial de uma imagem digital original à esquerda, a máscara de convolução ao centro, e a matriz resultante à direita. Abaixo, as operações matemáticas para ilustrar o valor final da três pixels na matriz resultante, o pixel azul de valor 137, o pixel amarelo de valor 151 e o pixel laranja de valor 51.

0	0	0	0	0	0	0	0	0	0	0	0
0	6	9	2	7	8	6	3	2	8	7	0
0	1	5	2	7	3	6	7	1	4	7	0
0	8	2	2	3	8	8	4	0	4	4	0
0	5	1	2	0	5	2	9	9	1	5	0
0	4	3	9	1	7	8	8	8	1	2	0
0	7	5	7	7	5	3	7	8	4	1	0
0	6	9	1	1	8	3	0	2	1	8	0
0	6	10	7	5	2	10	10	1	1	10	0
0	3	8	1	3	1	10	3	3	3	4	0
0	3	1	5	7	6	8	9	4	8	9	0
0	0	0	0	0	0	0	0	0	0	0	0

*

1	2	3
4	5	6
7	8	9

=

137	146	202	188	231	212	158	163	192	151
156	161	163	211	277	269	171	152	173	133
118	132	89	155	189	264	242	205	190	101
112	188	131	204	215	305	315	232	173	64
152	250	222	250	219	274	316	257	172	61
211	255	201	212	208	204	182	144	168	97
251	298	258	200	229	263	224	138	185	137
225	237	210	132	235	246	226	130	178	124
138	179	204	193	285	311	270	227	257	181
51	69	90	101	141	148	126	122	131	88

$137 = 1*0 + 2*0 + 3*0 + 4*0 + 5*6 + 6*9 + 7*0 + 8*1 + 9*5$
$151 = 1*0 + 2*0 + 3*0 + 4*8 + 5*7 + 6*0 + 7*4 + 8*7 + 9*0$
$51 = 1*0 + 2*3 + 3*8 + 4*0 + 5*3 + 6*1 + 7*0 + 8*0 + 9*0$


Fonte: ELO7. Princípios de Processamento de Imagens: uma introdução à convolução 2018 – Disponível em: <https://elo7.dev/convolucao/>, acesso em 06/06/2020

4. RESULTADOS

4.1 Análise dos canais do modelo *Lab*


As Figuras 8, 9 e 10 apresentam as imagens originais e as três componentes do espaço de cor *Lab* mostrados separadamente para cada uma das cenas consideradas.

Figura 8 – (a) Imagem 1, (b) canal *L*, (c) canal *a* (d) canal *b*.




Fonte: Autoria própria.

Figura 9 – (a) Imagem 2, (b) canal *L*, (c) canal *a* (d) canal *b*.



Fonte: Aatoria própria.


Figura 10 – (a) Imagem 3, (b) canal *L*, (c) canal *a* (d) canal *b*.




Fonte: Aatoria própria.

A Figura 11 apresenta os histogramas dos canais *Lab* para cada uma das imagens.


Figura 11 – Histogramas de cada um dos canais *Lab*, respectivamente, de (a) Imagem 1, (b) Imagem 2 e (c) Imagem 2 .



(a)



(b)




(c)


Fonte: Autoria própria.

Na Figura 12 são apresentados os resultados da aplicação do Método de Otsu para cada um dos canais do espaço de cor *Lab* da Imagem 1, Imagem 2 e Imagem 3.


Figura 12 – Imagens segmentadas pelo limiar de Otsu de cada um dos canais *Lab*, respectivamente de (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3.



(a)



(b)




(c)

Fonte: Autoria própria.

A Figura 13 apresenta o resultado da segmentação da classe cana-de-açúcar densa para cada um dos canais *Lab* da Imagem 1, mantendo-se os valores dos pixels originais e a Figura 14 uma região ampliada para que se possa analisar os resultados obtidos com os canais *a* e *b*.


Figura 13 – Resultado da segmentação pelos canais *Lab*, respectivamente, da Imagem 1.



Fonte: Autoria própria.

A partir da análise dos resultados obtidos escolheu-se o canal *a*, por apresentar uma melhor segmentação da cana-de-açúcar, como pode-se observar da Figura 14.

Figura 14 – (a) Imagem original de uma região de plantação de cana-de-açúcar da Imagem 1, (b) resultado da segmentação usando o canal *a* e (c) resultado da da segmentação usando o canal *b*.



(a)


(b)

(c)

Fonte: Autoria própria.

A Figura 15 apresenta os resultados da densidade de cana-de-açúcar nas Imagens 1, 2 e 3 após a convolução com a máscara de 100 x 100 pixels. Quanto mais próximo de 255 o valor do pixel, mais densa é a plantação de cana-de-açúcar no entorno.

Figura 15 – Estimativas de densidade de pés-de-cana para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3.



(a)

(b)

(c)

Fonte: Autoria própria.

4.2 Comparação dos índices

A seguir serão apresentados os resultados dos cálculos dos 10 índices discutidos no Capítulo 2.

4.2.1 Índice ExR

O ExR apresentou um bom resultado, separando as classes mais densas (pixels mais escuros), das menos densas (pixels mais claros) nas três imagens (ver Figura 16). Analisando a separação da classe carreador, há uma tendência de pixels ainda mais claros do que a classe de cana menos densa, porém na Imagem 3 não houve uma separação tão significativa.

Em relação à classe que representa mato competição, este índice não apresentou nenhuma segmentação relacionada à classe de cana mais densa.

Figura 16- Resultado da aplicação do índice ExR para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.




(a)



(b)

Continuação da Figura 16



(c)


Fonte: Autoria própria.

4.2.2 Índice NDI

O resultado de aplicação do índice NDI não separa as classes cana mais densa de cana menos densa (ver Figura 17). Há uma separação entre as classes carreador e mato competição, mas esta não é o objetivo deste projeto de pesquisa. Embora não sejam classes de interesse, esta separação também é importante para mostrar a efetividade do método.


Outro ponto que desqualifica o supracitado índice é o fato da grande presença de *outliers*, pixels aleatórios não agrupados que não representam classes distintas e atrapalham na classificação.

Figura 17- Resultado da aplicação do índice NDI para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colcoadas ao lado de cada resultado.



(a)

Continuação da Figura 17



(b)





(c)

Fonte: Autoria própria.

4.2.3 Índice ExG


A Figura 18 apresenta os resultados deste índice, podendo-se observar que não atendem aos objetivos deste trabalho, pois não separa em tonalidades de cinza os grupos de pixels das classes de interesse.

Figura 18- Resultado da aplicação do índice ExG para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.




(a)

Continuação da Figura 18



(b)



(c)

Fonte: Autoria própria.

4.2.4 Índice CIVE

O índice CIVE não apresentou boa relação de separação de cana mais densa e menos densa (ver Figura 19). Os pixels mais claros tem certa relação com cana menos densa nas Imagens 1 e 2, porém na Imagem 3 isto não ocorre.


Figura 19- Resultado da aplicação do índice CIVE para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.




Continuação da Figura 19



(a)



(b)



(c)

Fonte: Autoria própria.

4.2.5 Índice ExGR


O índice ExGR não apresenta uma separação significativa das classes cana mais densa e cana menos densa nas três imagens testadas (ver Figura 20).

Figura 20- Resultado da aplicação do índice ExGR para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.




(a)

Continuação da Figura 20



(b)



(c)


Fonte: autoria própria.

4.2.6 Índice NGRDI

Quanto aos resultados do índice NGRDI, não apresentaram uma pré-separação entre as classes por tons de cinza (ver Figura 21). Além disso, há muitos resultados de pixels que foram levados para o branco, tornando-se *outliers*, ou seja, dificultando assim a segmentação automática e consequente boa separação de classes.

Em relação à classe mato-competição, têm-se uma boa separação, porém este não é o objeto desta pesquisa. Esta separação, porém, pode ser utilizada para outras pesquisas relacionadas à separação de classe de mato competição, como por exemplo, segmentação automática desta classe em imagens de VANTs para aplicação de defensivos agrícolas.

Figura 21- Resultado da aplicação do índice NGRDI para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.




Fonte: Autoria própria.

4.2.7 Índice VEG

O índice VEG, assim como o NGRDI, não apresenta uma pré-separação entre as classes por tons de cinza (ver Figura 22). Além disso há muitos resultados de pixels que foram levados para o branco, tornando-se *outliers*, atrapalhando a separação de classes.

Figura 22- Resultado da aplicação do índice VEG para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.



(a)



(b)



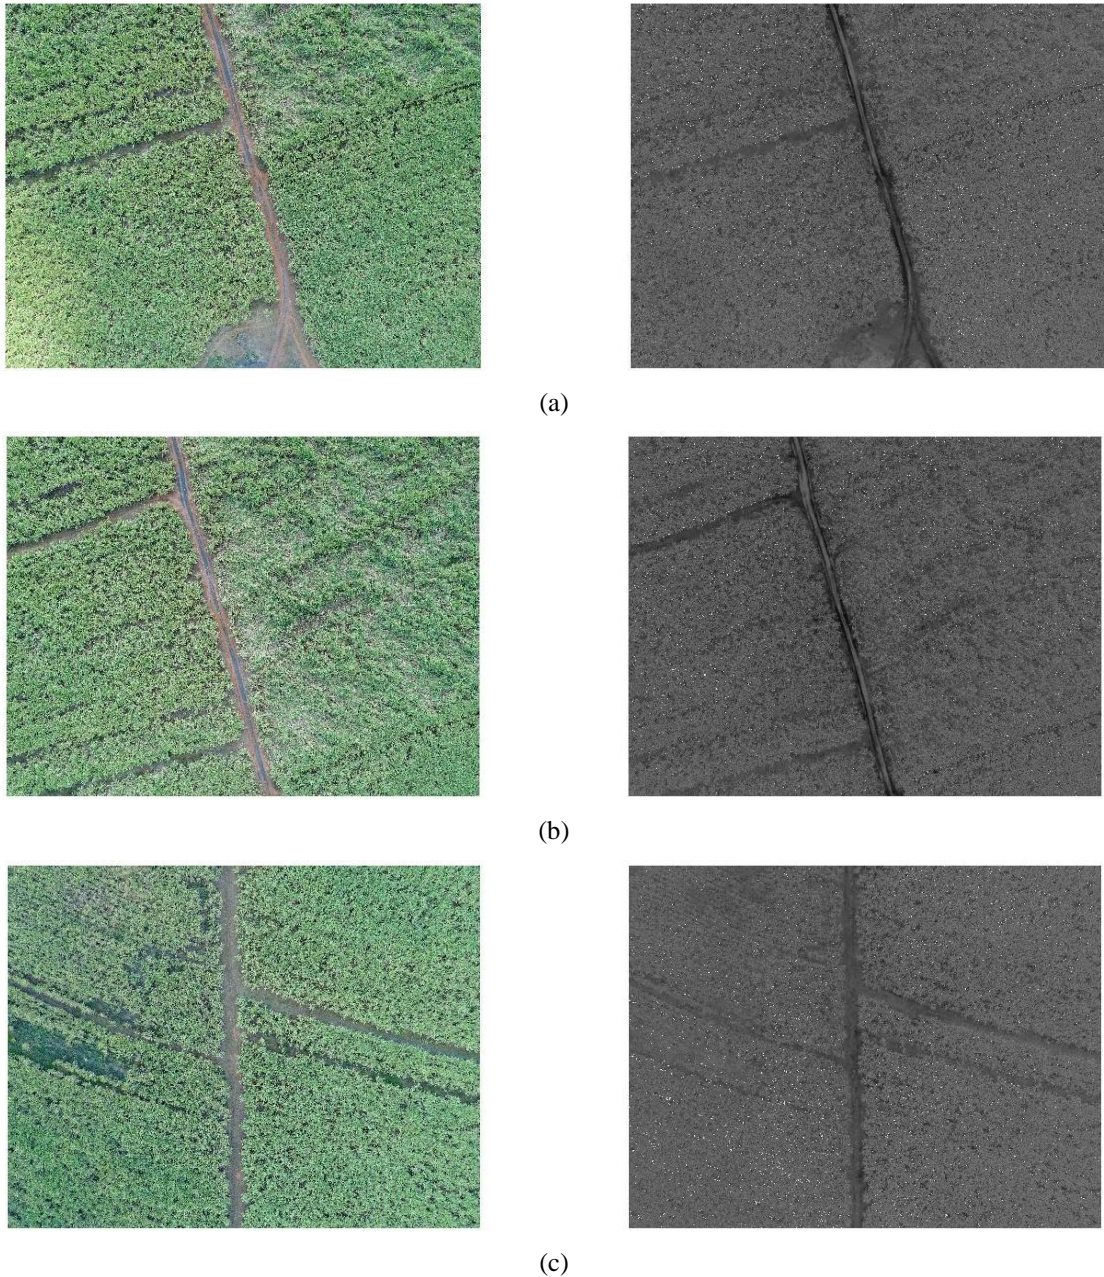
(c)

Fonte: Autoria própria.

4.2.8 Índice COM1

Conforme resultados apresentados na Figura 23, o índice COM1 não apresenta boa separação das classes consideradas nesta pesquisa.

Figura 23- Resultado da aplicação do índice COM1 para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.




Fonte: Autoria própria.


4.2.9 Índice MExG

O índice MExG apresenta bons resultado quanto à pré-separação de pixels pertencentes as classes de cana mais densa (tons claros) e menos densa (tons escuros) conforme pode ser observado na Figura 24. Outro ponto importante a ser observado é que a classe de mato-competição possui uma tendência de agrupamento com a classe de cana menos densa.

Figura 24- Resultado da aplicação do índice MExG para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.



(a)



(b)




(c)

Fonte: Autoria própria.

4.2.10 Índice COM2

Assim como os resultados da aplicação do índice COM1, o índice acima COM2 não apresenta uma separação relevante das classes testadas nesta pesquisa (ver Figura 25).

Figura 25- Resultado da aplicação do índice COM2 para: (a) Imagem 1, (b) Imagem 2 e (c) Imagem 3. Para facilitar a análise, as imagens originais foram colocadas ao lado de cada resultado.



Fonte: Autoria própria.

4.3 Comparativo entre os índices

Os índices listados por Hamuda, Glavin e Jones (2016) que obtiveram os melhores resultados quanto à separação das classes de cana mais densa para cana menos densa, nas Imagens 1, 2 e 3 foram o ExR, o NDI, o ExG e o MExG. As análises foram baseadas na interpretação visual da imagem resultante após os cálculos dos índices e também na avaliação

dos histogramas, onde buscou-se selecionar aqueles índices que levaram a maior separação dos valores dos pixels que representavam as duas classes de interesse.

A seguir apresenta-se a comparação da separação de cana mais densa com a cana menos densa após os cálculos dos 4 índices selecionados utilizando-se o método de segmentação de Otsu. Em seguida, o índice com melhor resultado será comparado com o uso do canal *a* do sistema *Lab*.

Para facilitar a análise visual, foi selecionada uma região da Imagem 1 que representam trechos com cana mais densa, cana menos densa e falhas na plantação (Figura 26).

Figura 26 – Região da Imagem 1 a ser usada para a comparação dos índices, mostrando com detalhe as características de densidade de cana de açúcar.



Fonte: Autoria própria.

A seguir são apresentados os resultados onde os pixels pretos representam cana menos densa ou falhas na plantação e os pixels brancos representam cana mais densa.


4.3.1 Segmentação da imagem transformada pelo índice ExR

O índice ExR apresentou um bom resultado como pode ser observado da Figura 27, separando a cana mais densa da cana menos densa, porém não representou de forma satisfatória as falhas na plantação.

Figura 27- Resultado da imagem transformada pelo índice ExR e segmentada pelo método de Otsu.



Fonte: Autoria própria.




4.3.2 Segmentação da imagem transformada pelo índice NDI

O índice NDI apresentou um bom resultado, separando também a cana mais densa da cana menos densa, porém, com maior detalhe quando comparado aos resultados obtidos com o índice ExR. No entanto, a região de falhas de plantação, embora também com resultados melhores, continuam sub segmentadas, não apresentando um resultado de separação de pixels homogêneos para melhor separar as classes (ver Figura 28).

Figura 28- Resultado da imagem transformada pelo índice NDI e segmentada pelo método de Otsu.




Fonte: Autoria própria.



4.3.3 Segmentação da imagem transformada pelo índice ExG

Como se pode observar na Figura 29, o resultado do índice ExG fica entre o resultado obtido como ExR e o NDI no que se refere a a quantidade de pixels pretos, que representa a cana menos densa.

Figura 29- Resultado da imagem transformada pelo índice ExG e segmentada pelo método de Otsu.




Fonte: Autoria própria.

4.3.4 Segmentação da imagem transformada pelo índice MExG

Como pode-se observar na Figura 30 o índice MExG separa bastante bem a cana mais densa da menos densa e das falhas na plantação. Este índice, diferentemente dos 3 [índices supracitados, segmenta de forma homogênea a cana menos densa, quando observamos as linhas de plantação de cana e seus intervalos de plantio.

Figura 30- Resultado da imagem transformada pelo índice MExG e segmentada pelo método de Otsu




Fonte: Autoria própria.

4.4 Comparando a segmentação da imagem transformada pelo índice MExG e pelo canal *a* do modelo *Lab*.

Após realizar a segmentação pelo método de Otsu, utilizando as imagens transformadas pelos índices ExR, NDI, ExG e MExG, pela análise visual obteve-se que o que melhor representa a classe de cana mais densa é o índice MExG. A seguir é apresentada a comparação do uso deste índice com o canal *a* do modelo *Lab*.

A Figura 31 apresenta o resultado obtido com cada um dos índices utilizando a segmentação pelo método de Otsu como máscara para a imagem original.

Figura 31- Segmentação da cana mais densa utilizando o resultado do método de Otsu como máscara para a imagem original e (a) índice MExG e (b) canal *a* do modelo *Lab*.



Fonte: Autoria própria.

Analisando as imagens da Figura 31 pode-se notar que os resultados são visualmente muito similares.

Foram realizadas mais duas comparações utilizando uma parte da Imagem 1 e uma parte da Imagem 2.

A parte destacada da Imagem 1 (Figura 32) possui, além das duas classes principais, cana mais densa e classe menos densa, a classe carreador.


Figura 32 – Parte da Imagem 1 com a presença das classe carreador, cana mais densa e cana menos densa.




Fonte: Autoria própria.

Como pode-se observar da Figura 33, os resultados da aplicação do índice MExG e do canal *a* do modelo *Lab* são visualmente muito similares no que se refere a segmentação da cana mais densa.

Figura 33 – Segmentação da cana mais densa presente na Figura 33 usando: (a) o canal *a* do modelo *Lab* e (b) o índice MExG.



(a)



(b)

Fonte: Autoria própria.

A parte destacada da Imagem 3 (Figura 34) possui, além das duas classes principais, cana mais densa e classe menos densa, a classe mato-competição.


Figura 34- Parte da Imagem 3 com as classes cana mais densa, cana menos densa e mato-competição.




Fonte: Autoria própria.

A Figura 35 apresenta os resultados da aplicação do índice MExG e do canal a do modelo Lab e como pode ser observado, em ambos os caso a classe mato-competição é agregada a classe de cana mais densa, ocasionando uma limitação para estimativa da densidade de cana.

Figura 35–Segmentação da cana mais densa presente na Figura 35 usando: (a) o canal a do modelo Lab e (b) o índice MExG.



(a)



(b)

Fonte: Autoria própria.

Como já mencionado no capítulo 3, o canal b do modelo Lab é o mais adequado para para separar a classe mato competição, porém nos testes realizados, não tem o mesmo desempenho na segmentação da classe cana mais densa.

5 CONSIDERAÇÕES FINAIS

Com os resultados obtidos neste trabalho pode-se afirmar que a segmentação utilizando os canais *a* e *b* do espaço de cor *Lab* podem auxiliar na classificação automática das diversas classes presentes em culturas agrícolas através do mapeamento aéreo por VANTs.

O método implementado que utiliza o canal *a* do modelo *Lab* e a segmentação pelo limiar de Otsu mostram-se apropriados para a separação da classe de cana mais densa, das demais (cana menos densa e solo exposto/carreador). Também mostrou-se que o canal *b* do modelo *Lab* pode ser utilizado para realçar a classe de mato-competição.

Com relação aos índices RGB de vegetação da literatura considerados neste trabalho, o que obteve o melhor resultado visual na segmentação da classe cana densa foi o MExG.

Os resultados obtidos com o índice MExG e o canal *a* do modelo *Lab* foram visualmente equivalentes.

Para a avaliação da densidade de cana-de-açúcar foi proposto um método baseado na convolução de uma máscara com o tamanho de um único pé de cana-de-açúcar isolado com a imagem segmentada da cana densa. Com esta densidade, pode-se, em trabalhos futuros, achar uma relação matemática para o cálculo de TCH com melhor precisão.

A partir do resultado da segmentação da cana mais densa é possível se aplicar insumos ou defensivos agrícolas com mais precisão. Além disso, ao conhecer com mais detalhes cada espaço plantado no canavial, pode-se gerenciar com mais eficiência a atuação das equipes de campo.

Com os métodos estudados também pode-se destacar a cana de menor densidade, permitindo que sejam realizados estudos sobre o que está levando a esta diminuição de densidade e se tomar a decisão de aplicar insumos, replantar ou reformar o canavial naquela região.

Como últimas considerações, entende-se que as imagens aéreas digitais estarão cada vez mais presentes no dia-a-dia da operação de monitoramento de culturas agrícolas principalmente em cana de açúcar, uma vez que os VANTs já se tornaram populares no Brasil e seu uso tem crescido com grande velocidade.

Desta forma, processos automáticos facilitarão as tomadas de decisão, controle de produtividade e permitirão conhecer melhor os canaviais a partir das relações das imagens aéreas com os fenômenos naturais, como saúde da planta, falhas de plantio, densidade do plantio e sua relação com o TCH.

REFERÊNCIAS

- ALVES, T. T. Cor, 2011. Disponível em: <http://corisectelmo.blogspot.com/2011/01/aula-21-espaco-de-cor-lab.html>
- DPI INPE. Processamento Digital de Imagens: filtragens espaciais. Disponível em: http://www.dpi.inpe.br/~carlos/Academicos/Cursos/Pdi/pdi_filtros.htm
- GOETHE, J. W. **Doutrina das cores**. (trad. Marco G. Giannotti) 4ª. ed. São Paulo: Nova Alexandria, 2013
<https://books.google.com.br/books?id=n3laDwAAQBAJ&pg=PT12&dq=%22cores+opostas%22&hl=pt-BR&sa=X&ved=0ahUKEwj1vbGdhoLqAhWZlIkGHVQJBkQ6AEILzAB#v=onepage&q=%22cores%20opostas%22&f=false>
- HAMUDA, E., GLAVIN, M. e JONES, E.. **A survey of image processing techniques for plant extraction and segmentation in the field**. Computers and Electronics in Agriculture, 125, pp.184-199. 2016.
- HILLNHÜTTER, A.-K.MAHLEINR.A.SIKORAE.-C.OERKE. **Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields**. **Field Crops Research Volume 122, Issue 1**, 28 April 2011. pp. 70-77;
- MARTINS, A. C. G. **Introdução a Análise de Imagens Digitais**, 2018. Disponível em: <https://www.sorocaba.unesp.br/Home/Graduacao/EngenhariaAmbiental/antonio/imagens.pdf>
- MARTINS, G. D.; GALO, M. D. L. T. **Caracterização Espectral da Cana-de-açúcar infectada por Nematoides e Migdolus Fryanus por Espectrorradiometria de Campo**. Boletim de Ciências Geodésicas, Curitiba, 2015;
- OUMAR, Z.; MUTANGA, O. **Integrating environmental variables and WorldView-2 image data to improve the prediction and mapping of Thaumastocoris peregrinus (bronze bug) damage in plantation forests**. IPRS Journal of Photogrammetry and Remote Sensing, 2014, 87, 39-46;
- OTSU, N. "A threshold selection method from gray-level histogram", IEEE Transactions on Systems Man Cybernet, SMC-8 pp. 62-66, 1978.
- RANGAYYAN, R.M.; ACHA, B.; SERRANO, C. **Color image processing with biomedical applications**. Bellingham: SPIE Press, 2011.
- ROCHA, J. C. Cor luz, cor pigmento e os sistemas RGB e CMY, 2011. **Revista belas artes**. Disponível em: <http://www.belasartes.br/revistabelasartes/downloads/artigos/3/cor-luz-cor-pigmento-e-os-sistemas-rgb-e-cmy.pdf>. Acesso em 20/06/2020
- RUDORFF, B. F. T.; at al. **Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using Landsat Data**. Remote Sensing. 2010.
- SEKULER, R. e BLAKE, R. **Perception**. 3ª. ed.Porto Alegre: McGraw Hill, 1990

SIMÕES, E. Eletromagnetismo: para além das Leis de Newton. Revista Pesquisa & Extensão, Montes Claros/MG, v. 4, nº 1, p. 07-14, 2014.

TAKATSUI, F. **Sistema CIE LAB**: análise computacional de fotografias, 2011. Faculdade de Odontologia de Araraquara, da Universidade Estadual Paulista. Disponível em: https://www.foar.unesp.br/Home/Pos-Graduacao/LatoSensu/CienciasOdontologicas/takatsui_f_me_arafo.pdf . Acesso em 20/06/2019.