

**UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS DE JABOTICABAL**

**UTILIZAÇÃO DE IMAGENS DE SENSORIAMENTO
REMOTO ATRAVÉS DE SENSOR MULTIESPECTRAL
PARA AVALIAR A VARIABILIDADE DE FÓSFORO E
POTÁSSIO NA CULTURA DA CANA-DE-AÇÚCAR**

Almir Salvador Neto
Engenheiro Agrônomo

**UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS DE JABOTICABAL**

**UTILIZAÇÃO DE IMAGENS DE SENSORIAMENTO
REMOTO ATRAVÉS DE SENSOR MULTIESPECTRAL
PARA AVALIAR A VARIABILIDADE DE FÓSFORO E
POTÁSSIO NA CULTURA DA CANA-DE-AÇÚCAR**

Discente: Almir Salvador Neto

Orientador: Prof. Dr. José Eduardo Corá

**Tese apresentada à Faculdade de
Ciências Agrárias e Veterinárias –
Unesp, Campus de Jaboticabal, como
Parte das exigências para a obtenção
do título de Doutor em Agronomia pelo
Programa de Pós-graduação em
Produção Vegetal.**

S182u

Salvador Neto, Almir

Utilização de imagens de sensoriamento remoto através de sensor multiespectral para avaliar a variabilidade de fósforo e potássio na cultura da cana-de-açúcar. / Almir Salvador Neto. -- Jaboticabal, 2022
58 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: José Eduardo Corá

1. Agricultura de Precisão. 2. Cana-de-açúcar. 3. Zonas de Manejo.
4. Fósforo. 5. Potássio. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO


TÍTULO DA TESE: UTILIZAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO ATRAVÉS DE SENSOR MULTIESPECTRAL PARA AVALIAR A VARIABILIDADE DE FÓSFORO E POTÁSSIO NA CULTURA DA CANA-DE-AÇÚCAR.


AUTOR: ALMIR SALVADOR NETO


ORIENTADOR: JOSÉ EDUARDO CORÁ


Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA (PRODUÇÃO VEGETAL), pela Comissão Examinadora:


Prof. Dr. JOSÉ EDUARDO CORÁ (Participação Virtual)
Departamento de Ciências da Produção Agrícola / FCAV / UNESP - Jaboticabal


Prof. Dr. ADOLFO VALENTE MARCELO (Participação Virtual)
Centro Universitário de Rio Preto - UNIRP / São José do Rio Preto/SP


Prof. Dr. MARCOS SALES RODRIGUES (Participação Virtual)
Universidade Federal do Vale do São Francisco - Univasf / Petrolina/PE


Pós-Doutorando GUILHERME MARTINELI SANCHES (Participação Virtual)
Departamento de Solos-ESALQ/USP / Piracicaba/SP


Dr. CRISTIANO ZERBATO (Participação Virtual)
Agromais Serviços Agrômicos Ltda - Votuporanga/SP

Jaboticabal, 04 de julho de 2022

DADOS CURRICULARES DO AUTOR

Engenheiro Agrônomo formado pela Universidade Estadual Paulista “Júlio de Mesquita Filho” – Faculdade de Ciências Agrárias e Veterinárias – Campus de Jaboticabal/SP (2012 – 2016).

Bolsista Fapesp ao longo da graduação, com o projeto intitulado “Adubação nitrogenada na cultura do feijoeiro”.

Estagiário pela empresa Stoller do Brasil, atuando no departamento técnico e comercial com a prospecção de clientes, posicionamento de tecnologias e treinamento técnico de equipes na região de Rondonópolis/MT. Com foco nas culturas de soja, algodão e milho (2016 – 2017).

Engenheiro Agrônomo de atendimento a grandes clientes pela Stoller do Brasil, atuando no departamento comercial e técnico com o objetivo de atender clientes de forma personalizada, treinamento técnico de equipes, posicionamento de tecnologias, prospecção estratégica de vendas e liderança de pessoas. Culturas soja, milho e algodão (2017 – 2018).

Doutorando pelo programa de Pós-graduação em Produção vegetal pela Unesp – Campus de Jaboticabal. Atuando no desenvolvimento do projeto de pesquisa, o qual envolve a utilização de ferramentas de sensoriamento remoto na avaliação da variabilidade da produtividade da cana-de-açúcar e dos teores de fósforo e potássio no solo e nas plantas (2018 – 2022).

Engenheiro Agrônomo na Usina São Martinho. Atua na área de experimentação agrícola, com projetos que envolvem nutrição, fisiologia, desempenho varietal e tecnologias na cultura da cana-de-açúcar e consórcio com milho e soja (2021 – Atual).

Dedicatória

Dedico à DEUS, e segundo a um grande amigo e conselheiro in memoriam Marcelo Scatolin. Amigo, o qual foi o grande responsável por inúmeras conquistas em minha vida, sempre foi um grande parceiro e conselheiro, nos ajudando a tomar excelentes decisões desde a época de graduação até o final da sua vida. OBRIGADO MEU GRANDE AMIGO.

AGRADECIMENTOS

Agradeço à DEUS, primeiro por me conceder a vida e nos capacitar para as situações da vida.

Ao Prof. Dr. José Eduardo Corá por além de ser orientador foi um pai, nos guiando em conselhos, conhecimentos, formas de vida e além de tudo orientando a ser uma pessoa melhor a cada dia.

Aos meus pais Almir Salvador Júnior e Eliete Affonso Salvador por me concederem a vida, e mostrar os caminhos a serem seguidos de forma justa, entusiasmada e sempre com respeito ao próximo.

A minha querida irmã Maria Eduarda Salvador e minha namorada Jéssica Caroline Villar por nos ajudar em todos os momentos e nunca nos deixar levar pelo desânimo.

Aos meus companheiros de departamento Hugo Miranda Faria, Vinicius Marchioro, Henildo Pereira de Sousa, Michele Soares e Adauto Alves.

Aos colaboradores da Fazenda de Ensino, Pesquisa e Extensão da Unesp – Campus de Jaboticabal.

Aos colaboradores da Usina São Martinho.

Agradeço à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) - número de financiamento 2020/04486-9.

SUMÁRIO

1) Introdução.....	1
2) Revisão Bibliográfica.....	3
2.1) Sensoriamento remoto na identificação de zonas de manejo	3
2.2) Sensoriamento remoto na avaliação da variabilidade dos teores de nutrientes no solo e na planta	7
3) Material e métodos	10
3.1) Área de estudo	10
3.2) Sensoriamento remoto	12
3.2.1) Aquisição das imagens.....	12
3.2.2) Índices de vegetação	13
3.2.3) Extração dos valores de pixels	13
3.3) Amostragem de solo e plantas	14
3.4) Mapa temático da produtividade (Mg ha^{-1})	15
3.5) Definição das zonas de manejo	15
3.6) Estatística dos dados de sensoriamento remoto.....	16
4) Resultados	16
4.1) Variabilidade espacial de refletância dos índices de vegetação na cultura da cana-de-açúcar na safra 2018/2019	16
4.2) Variabilidade espacial e temporal da refletância dos índices de vegetação da cultura da cana-de-açúcar na safra 2019/2020.....	19
4.3) Variabilidade espacial da refletância dos índices de vegetação da cultura da cana-de-açúcar na safra 2019/2020	22
4.4) Mapa de Produtividade.....	25
4.5) Delimitação das zonas de manejo.....	26
4.6) Variabilidade dos teores de fósforo e potássio no solo e na planta	29
4.6.1) Análise química da fertilidade dos solos nas diferentes zonas de manejo....	29
4.6.2) Variabilidade de fósforo e potássio nos tecidos vegetais.....	31
4.7) Avaliação da textura do solo nas diferentes zonas de manejo.....	37
5) Discussão.....	38
6) Conclusão	43
7) Referências Bibliográficas	44

UTILIZAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO ATRAVÉS DE SENSOR MULTIESPECTRAL PARA AVALIAR A VARIABILIDADE DE FÓSFORO E POTÁSSIO NA CULTURA DA CANA-DE-AÇÚCAR

RESUMO: O objetivo do projeto de pesquisa foi utilizar imagens de sensoriamento remoto através de sensor multiespectral para avaliação da variabilidade espacial e temporal da produtividade da cana-de-açúcar, definição de zonas de manejo e avaliação da variabilidade de fósforo e potássio no solo e nos tecidos vegetais. Para atingir a proposta, uma área comercial de cana-de-açúcar foi monitorada ao longo de duas safras 2018/2019 e 2019/2020 com a utilização de um sensor multiespectral embarcado em drone, com o intuito de validar os índices de vegetação para a avaliação da variabilidade espacial e temporal da cultura da cana-de-açúcar, identificação de zonas de manejo e da variabilidade de fósforo e potássio. Os índices de vegetação GRVI, NDVI, NDRE, GNDVI, SAVI e RVI permitiram por meio das refletâncias avaliar a variabilidade espacial e temporal da produtividade da cultura da cana-de-açúcar, identificar as zonas de manejo, e por fim identificar a variabilidade dos nutrientes fósforo e potássio. O índice de vegetação RVI foi o mais preciso em combinação com o mapa de produtividade para definição das zonas de manejo, seguido pelo NDVI, NDRE, GNDVI, SAVI e GRVI. Além disso, permitiram identificar a fertilidade do solo nas respectivas zonas de manejo, a extração e exportação de P e K, as classes texturais, e por fim concluiu que os índices de vegetação são ferramentas precisas tanto para a delimitação de zonas de manejo quanto para o manejo adequado de fertilizantes.

Palavras chaves: Sensoriamento remoto, agricultura de precisão, cana-de-açúcar, zonas de manejo, fósforo, potássio

REMOTE SENSING TECHNIQUES IN THE ASSESSMENT OF SPATIAL VARIABILITY OF SUGARCANE CULTURE PRODUCTIVITY AND SOIL PHOSPHORUS AND POTASSIUM CONTENTS

ABSTRACT: The objective of the research project was to use remote sensing images through a multispectral sensor to evaluate the spatial and temporal variability of sugarcane productivity, define management zones and evaluate the variability of phosphorus and potassium in soil and tissues. vegetable. To achieve the proposal, a commercial area of sugarcane was monitored over two harvests 2018/2019 and 2019/2020 with the use of a multispectral sensor embedded in a drone, in order to validate the vegetation indices for the evaluation of the spatial and temporal variability of the sugarcane crop, identification of management zones and the variability of phosphorus and potassium. The vegetation indices GRVI, NDVI, NDRE, GNDVI, SAVI and RVI made it possible, through the reflectances, to evaluate the spatial and temporal variability of the productivity of the sugarcane crop, to identify the management zones, and finally to identify the variability of the nutrients phosphorus and potassium. The RVI vegetation index was the most accurate in combination with the productivity map to define management zones, followed by NDVI, NDRE, GNDVI, SAVI and GRVI. In addition, they made it possible to identify soil fertility in the respective management zones, the extraction and export of P and K, the textural classes, and finally concluded that the vegetation indices are precise tools both for the delimitation of management zones and for proper management of fertilizers.

Keywords: Remote sensing, precision agriculture, sugarcane, management zones, phosphorus, potassium

1) Introdução

A cultura da cana-de-açúcar é a mais importante para o sistema de produção de açúcar e etanol em climas tropicais, sendo o Brasil o principal produtor mundial, com área de produção de 8,2 milhões de hectares, com uma produção de 40 milhões de toneladas de açúcar e 24,8 bilhões de litros de etanol. O estado de São Paulo é o principal produtor, com 4 milhões de hectares (50%) de área colhida, com produção de 24,1 milhões de toneladas de açúcar e 10,7 bilhões de litros de etanol (Conab, 2022).

Com a inovação do setor agrícola, diversas tecnologias são utilizadas na gestão da variabilidade e diagnósticos das lavouras. De acordo com a Embrapa (2020) 84% dos produtores utilizam de um aporte tecnológico, tais como softwares, internet, equipamentos com GPS, sensores e demais ferramentas, a fim de tornar o processo produtivo mais rentável. Em agricultura de precisão (AP), o objetivo é realizar a gestão da agricultura por meio de tecnologias que possibilitam identificar e quantificar a variabilidade espacial e temporal da produtividade da cultura, dos atributos do solo e de plantas, e dos demais fatores de produção, como pragas, doenças, falha de plantio, presença de plantas daninhas, comportamento varietal, entre outros. Ou seja, é o levantamento de dados de campo, mapeamento e compreensão da variabilidade espacial e temporal dos fatores de produção, para posteriormente realizar a gestão dos fatores de produção e otimizar as tomadas de decisão no campo (Zhang & Kovacs, 2012; Barbedo et al., 2021; Cardoso et al., 2022).

Um dos propósitos da AP é otimizar a aplicação de insumos e incrementar rendimentos, por meio da utilização de técnicas que promovam a compreensão da variabilidade da produtividade e dos atributos químicos do solo. O método mais utilizado na identificação da variabilidade da produtividade e na delimitação de zonas de manejo, dos atributos químicos e físicos do solo, a fim de determinar as melhores estratégias de manejo é por meio da obtenção do mapa de produtividade da cultura, o qual é adquirido por meio de dados de produtividade coletados a partir de monitores de colheita (Sana et al., 2014; Damian et al., 2018; Martínez-Casasnovas et al., 2018; Gelain et al., 2021). Por outro lado, monitores de colheita para a cultura da cana-de-açúcar ainda não são muito utilizados no Brasil, em decorrência da viabilidade operacional, pois na aquisição dos dados de produtividade é necessário levar em consideração a alta resolução dos dados, devido a baixa velocidade de colheita e espaçamento das entrelinhas, além disso a grande variabilidade de biomassa pode provocar alterações no sistema de monitoramento (Canata et al., 2021). No entanto, outras ferramentas podem ser utilizadas para o conhecimento da

variabilidade espacial e temporal da produtividade das culturas, dos atributos do solo e da planta, com o objetivo de definir as zonas de manejo para a adoção da AP. As ferramentas incluem imagens de satélites e de sensores acoplados em veículos aéreos não tripulados (VANTS), obtidas por técnicas de sensoriamento remoto (SR) com base na refletância das plantas, e posteriormente na determinação de índices de vegetação. O SR pode ser utilizado para detectar diferentes estágios de desenvolvimento da cultura, condições de solo, deficiências nutricionais, estresses hídricos da planta, definição de zonas de manejo, entre outros (Candiago et al., 2015, Maresma et al., 2016; Loozen et al., 2019, Yeom et al., 2019, Asahapure et al., 2019, Campos et al., 2019, Di Gennaro et al., 2019, Lima-Cueto et al., 2019, Thompson et al., 2020; Canata et al., 2021, Denora et al., 2022).

Na avaliação do estado nutricional das culturas com a utilização do SR a maioria das pesquisas encontradas na literatura trabalham com índices de vegetação (IV) para a determinação dos teores de nitrogênio (N) nas plantas (Cilia et al., 2014; Maresma et al., 2016; Guan et al., 2019, Thompson et al., 2020, Pereira et al., 2022), pelo fato de ser o elemento diretamente ligado a molécula de clorofila (Malavolta, 2006; Otto et al., 2019) e sua deficiência pode ser facilmente detectada pela variação do espectro. No entanto, os elementos fósforo (P) e potássio (K) são igualmente essenciais às plantas e apresentam funções fundamentais no processo fotossintético das plantas (Bang et al., 2020), com isso há potencial de avaliar esses nutrientes por meio do SR. Na literatura existem trabalhos que demonstram a utilização de técnicas de SR para o desenvolvimento de IV relacionados ao estado nutricional de P e K para diversas culturas, tais como para o trigo (Pimstein et al., 2011; Mahajan et al., 2014; Lu et al., 2021), milho (Osborne et al., 2002; Furlanetto et al., 2021; Yang et al., 2021), gramíneas (Loozen et al., 2019), canola (Severtson et al., 2016; Montgomery et al., 2020) e cana-de-açúcar (Lisboa et al., 2018).

No cultivo da cana-de-açúcar a disponibilidade de P e K são alguns dos principais fatores que limitam o desenvolvimento e o rendimento da cultura, por serem nutrientes essenciais ao metabolismo das plantas. No caso do P em solos tropicais existe o processo de fixação, em que o nutriente pode ser fixado e tornar-se não mais disponível para as plantas (Zambrosi et al., 2015; Rajj, 2017). Quanto a participação do P no metabolismo da planta, o nutriente participa de funções estruturais em moléculas (ATP e NADPH), atua em processos de transferência de energia, na fotossíntese, na síntese de proteínas, translocação e armazenamento de açúcares (Malavolta, 2006), e para que todos os

processos aconteçam de forma adequada é necessário em torno de 0.19 a 0.25 Kg de P para a produção de uma tonelada de colmo de cana-de-açúcar.

Quanto ao K, o nutriente pode sofrer perdas por meio do processo de lixiviação, diminuindo os teores do nutriente na solução do solo, principalmente em solos de texturas mais arenosas (Yamada & Lopes, 1999; Rajj, 2017). Para a produção de uma tonelada de colmos é necessário em torno de 1.74 a 2.14 Kg de K (Orlando Filho, 1983; Otto et al., 2019), pois o nutriente atua no metabolismo da planta como ativador enzimático, na síntese de proteínas, regula a abertura e fechamento dos estômatos, aumenta a assimilação de CO₂, reduz a taxa de transpiração, ou seja, participa de processos fotossintéticos, sendo assim uma planta suprida adequadamente com o nutriente, os danos sob condições de estresse fisiológico são menores. Por outro lado, a deficiência dos nutrientes acarreta prejuízos ao aparato fotossintético, no desenvolvimento vegetativo e do sistema radicular, e por fim afeta a produtividade das culturas. (Humbert et al., 1968; Marschner, 1995; Malavolta, 2006; Prado, 2008; Bang et al., 2020).

O objetivo do trabalho foi definir as zonas de manejo na cultura da cana-de-açúcar, por meio de imagens de sensoriamento remoto através de sensor multiespectral e do mapa de produtividade da cultura, posteriormente foram avaliados os teores de P e K no solo e nas plantas das diferentes zonas de manejo, a fim de possibilitar diferentes estratégias de manejo.

2) Revisão Bibliográfica

2.1) Sensoriamento remoto na identificação de zonas de manejo

Por meio da AP e do avanço tecnológico é possível realizar a gestão da agricultura com o uso de ferramentas de SR que quantificam a variabilidade da produtividade das culturas, dos atributos químicos e físicos do solo, e de fatores que afetam a produção agrícola, tais como pragas, doenças, deficiências nutricionais, entre outros. No delineamento de zonas de manejo é necessário implantar a AP, pois o objetivo é identificar áreas com diferentes potenciais produtivos, a fim de manejar de forma diversa os diferentes locais de potenciais produtivos, e para isso é necessário o levantamento de dados de campo, interpretação e ajustes dos dados para realizar uma gestão das práticas agrícolas, e por fim otimizar as tomadas de decisão no manejo da cultura, seja por aplicação de fertilizantes, inseticidas, fungicidas, lâminas de irrigação, entre outros (Moran et al., 1997; Som-ard et al., 2021).

Um método para quantificar a variabilidade da produtividade das culturas e definir as zonas de manejo são os mapas de colheita ou mapas de produtividade, obtidos por

monitores de produtividade (Sana et al., 2014; Gilain et al., 2021). Por outro lado, a validação de monitores de colheita para a cultura da cana-de-açúcar está em processo de pesquisa, pois existem questões operacionais a serem corrigidas, tais como ruídos e alterações na aquisição dos dados, devido ao grande volume de biomassa da cultura (Canata et al., 2021). Com isso, outras ferramentas tecnológicas podem ser utilizadas na definição de zonas de manejo em AP, tais como o SR, por meio de imagens aéreas de sensores acoplados em VANTS, imagens de satélites (Candiago et al., 2015; Damian et al., 2018; Martínez-Casasnovas et al., 2018; Campos et al., 2019; Di Gennaro et al., 2019; Canata et al., 2021 & Denora et al., 2022) e sensores de condutividade elétrica aparente do solo (Peralta et al., 2013; Sanches et al., 2022). Com o uso do SR é possível a identificação dos estresses fisiológicos causados nas lavouras, seja nutricional, por ataque de pragas, deficiências hídricas, entre outros, pois ocorrem alterações fisiológicas nas plantas, consequentemente a refletância da planta é afetada, acarretando alterações nos comprimentos de onda dos sensores, nas regiões do visível, infravermelho e infravermelho próximo, pois são regiões do espectro eletromagnético que correlacionam com alterações nas atividades fotossintéticas das plantas (Epstein, 1965; Curran, 1989; Moreno et al., 2017).

Diversos trabalhos de pesquisa utilizaram o SR como ferramenta na avaliação da variabilidade espacial e temporal das culturas, e por fim na definição de zonas de manejo, a fim de tratar as diferentes áreas de potenciais produtivos de acordo com o que é possível produzir em cada uma delas, e além do mais poder realizar o manejo adequado de forma que o sistema de produção possa ser mais rentável e sustentável. Candiago et al., (2015) ao utilizarem um sensor multiespectral acoplado em um VANT na avaliação de campos de cultivo de tomate, observaram que valores superiores dos índices de vegetação NDVI, GNDVI e SAVI indicaram regiões de elevado vigor vegetativo. Por outro lado, áreas de valores inferiores dos índices de vegetação foram identificados como campos de baixa produção de biomassa, e por consequência encontrados os fatores limitantes, os quais foram a presença de doenças no tomateiro, deficiências nutricionais e menor teor de argila no solo. Por fim, a pesquisa concluiu que os índices de vegetação foram ferramentas precisas na identificação da variabilidade do vigor vegetativo da lavoura e na identificação de diferentes zonas de manejo.

Marino et al., (2018) avaliaram a variabilidade espacial e temporal da cultura do trigo com a utilização de um sensor multiespectral acoplado em um VANT. Os voos com o sensor foram realizados no estágio inicial da cultura, no estágio de perfilhamento e na

época de colheita. Os índices de vegetação utilizados foram o NDVI e SAVI. No estágio inicial da cultura os índices de vegetação apresentaram valores diferentes no espectro, pois com o NDVI os valores foram de 0.38, 0.36 e 0.29, já para o SAVI foram de 0.59, 0.55 e 0.54. Na época de perfilhamento, os valores de NDVI foram 0.67, 0.61 e 0.48, já o SAVI foi de 0.83, 0.72 e 0.59. No período de colheita os valores de NDVI foram 0.79, 0.76 e 0.57, e para o SAVI 1.03, 1 e 0.86. Com os dados dos índices de vegetação, os autores concluíram que nas regiões de valores superiores ao longo do ciclo da cultura o potencial produtivo da lavoura foi superior, com uma produtividade de 6.8 Mg ha^{-1} , para as regiões em que os índices de vegetação foram classificados como de valores intermediários, a produtividade foi de 5.8 Mg ha^{-1} , e para os locais em que os índices de vegetação apresentaram valores inferiores, a produtividade foi de 4.6 Mg ha^{-1} . De acordo com os resultados obtidos, os autores concluíram que os índices de vegetação foram precisos na avaliação da variabilidade espacial e temporal da produtividade do trigo, e consequentemente na identificação de zonas de manejo.

Campos et al., (2019) ao trabalharem com SR em vinhedos, por meio do uso de um sensor multiespectral acoplado em VANT na identificação de zonas de manejo para a aplicação de defensivos agrícolas, observaram que valores superiores de NDVI indicaram áreas de maior produção de biomassa, em que o coeficiente de determinação entre NDVI e a produção de biomassa foi de $R^2 = 0.76$. Ao obterem um mapa de vigor do dossel da cultura, identificaram regiões de alto vigor, médio vigor e baixo vigor para a aplicação de diferentes doses de volume de calda. Nas regiões de alto vigor, a dose do volume de calda foi de 250 L ha^{-1} , todavia na região de baixo vigor a dose foi de 150 L ha^{-1} , ou seja, a pesquisa mostrou que é possível identificar as diferentes zonas de manejo para a aplicação de defensivos. Di Gennaro et al., (2019) ao avaliarem a variabilidade espacial em vinhedos observaram a zona de manejo de potencial produtivo superior com uma produção de 8.3 Kg de biomassa por vinha quando obtiveram no espectro valores superiores de NDVI, e para zonas de manejo de baixo potencial os valores do índice de vegetação foram inferiores.

Além dos trabalhos de pesquisa difundirem o potencial de uso do SR na identificação de zonas de manejo, outros pesquisadores além de identificar as diferentes zonas de manejo também observaram que os índices de vegetação foram precisos na avaliação das produtividades agrícolas, tais como na cultura da soja (Damian et al., 2018), cana-de-açúcar (Canata et al., 2021; Dimov et al., 2022), milho (Maresma et al., 2016;

Martínez-Casasnovas et al., 2018; Burns et al., 2022; Meirelles, 2022) e trigo (Denora et al., 2022).

Damian et al., (2018) ao mapearem a variabilidade espacial e temporal da cultura da soja, utilizaram mapas de produtividade oriundos dos monitores de colheita e imagens de satélites Landsat 7, com o uso do índice de vegetação NDVI. O mapeamento foi realizado ao longo de três safras e observaram que regiões do talhão que apresentaram valores superiores de NDVI corresponderam a regiões de melhores produtividades, com isso a área foi dividida em duas zonas de manejo, uma de alto potencial produtivo e a outra de baixo potencial produtivo. Para a validação das ferramentas de AP foram preditos modelos de regressão, os quais apresentaram os seguintes coeficientes de determinação entre imagens de satélites e dados do monitor de produtividade, $R^2 = 0.81$ para a área de alto potencial, e $R^2 = 0.78$ para a de baixo potencial, e por fim chegaram à conclusão de que as imagens de NDVI são precisas na delimitação de zonas de manejo.

Denora et al., (2022) ao pesquisarem como definir zonas de manejo com ferramentas de AP na cultura do trigo, utilizaram dados de um monitor de colheita na obtenção da produtividade, imagens de um sensor multiespectral acoplado a um VANT e um sensor de condutividade elétrica aparente do solo. Observaram que as regiões mais produtivas apresentaram valores superiores de índices de vegetação, a qual apresentou uma produtividade de 1.4 Mg ha^{-1} a mais quando comparada a região de baixo potencial produtivo. Além disso, os sensores de condutividade elétrica do solo foram correlacionados com os mapas de NDVI e NDRE, e com isso apresentaram valores de $R^2 = 0.56$ e 0.52 na época de florescimento do trigo. Ao investigarem os fatores que interferiram nas diferentes zonas de manejo, concluíram que os diferentes teores de argila e matéria orgânica no solo acarretaram incremento na produtividade, já o teor de fósforo no solo foi semelhante em ambas as zonas de manejo.

Martínez-Casasnovas et al., (2018) ao avaliarem o delineamento de zonas de manejo na cultura do milho com o uso de dados de produtividade de um monitor instalado na colhedora, imagens de satélites provenientes do Sentinel-2A, dados de condutividade elétrica aparente do solo e topografia do terreno, observaram um resultado preciso na gestão da variabilidade. Os dados inferiores de NDVI e de condutividade elétrica aparente do solo identificaram uma região em condição de salinidade no solo, a qual afetou de forma negativa a produtividade. Por meio dessas ferramentas de avaliação da variabilidade da produtividade, a área foi dividida em três classes de manejo, as quais foram classificadas como de alto potencial produtivo, médio potencial produtivo e baixo

potencial produtivo por meio do uso da ferramenta fuzzy k-means, a qual obteve o resultado mais preciso com os menores valores de FPI (Índice de Performance Fuzzy) e o Índice de Entropia de Partição Modificada (MPE). Meirelles (2022) ao avaliarem a produtividade da cultura do milho com a utilização de um monitor de colheita encontraram resultados satisfatórios nas correlações com os índices de vegetação NDVI e NDRE provenientes de imagens de satélite. O NDVI apresentou um $R^2 = 0.7$, em que a imagem foi obtida na época do estágio vegetativo da cultura, já o NDRE o melhor resultado foi na época reprodutiva do milho com um $R^2 = 0.58$.

Para a cultura da cana-de-açúcar apesar de algumas limitações ainda impostas na obtenção de mapas de produtividade, alguns pesquisadores não medem esforços para o estudo da variabilidade da produtividade da cultura, como é o caso de Canata et al., (2021) que ao obterem o mapa de produtividade da cultura da cana-de-açúcar, por meio de um monitor de colheita comercial e ao utilizarem como ferramenta de complemento as imagens de satélites Sentinel-2A delimitaram as zonas de manejo para a cultura. Na validação das tecnologias foi utilizado o método RandomForest na obtenção de modelos de regressão entre índices de vegetação e dados de produtividade, e com isso os valores de R^2 foram 0.58 para NDVI, 0.60 para NDRE e 0.57 para GNDVI e concluiu que os índices de vegetação são precisos na predição da produtividade e podem ser utilizados na definição de zonas de manejo. Já Dimov et al., (2022) ao utilizarem índices de vegetação de imagens de satélites e estimativa da produtividade da cana-de-açúcar por meio de levantamento em campo de plantas, obtiveram valores significativos na predição da produtividade, em torno de $R^2 = 0.6$ para NDVI e 0.65 para NDRE.

2.2) Sensoriamento remoto na avaliação da variabilidade dos teores de nutrientes no solo e na planta

Para a identificação da variabilidade espacial e temporal de atributos químicos do solo e da planta por meio do uso de SR, e posteriormente a recomendação de fertilizantes as pesquisas apresentam maior ênfase para o N (Molin et al., 2010; Molin & Amaral, 2011; Motomiya et al., 2009; Maresma et al., 2016; Thompson et al., 2020; Burns et al., 2022; Pereira et al., 2022), pelo fato de o nutriente ser essencial as plantas, estar ligado a processos fotossintéticos e participar de moléculas estruturais, tais como a molécula da clorofila. O teor de N nas plantas é fortemente correlacionado com os teores de clorofila, e no caso plantas deficientes apresentam clorose, ocorrendo mudanças fisiológicas nas plantas, posteriormente alterações na refletância do espectro do visível e infravermelho

(NIR) (Curran, 1989; Bang et al., 2020). Por outro lado, os nutrientes P e K são macronutrientes importantes que atuam nos processos fotossintéticos e na produtividade das culturas. Com isso, existem diversos pesquisadores que estão trabalhando na identificação das variabilidades desses nutrientes em diferentes culturas, por meio da utilização de sensores (Osborne et al., 2002; Mahajan et al., 2014; Severtson et al., 2016; Guo et al., 2017; Lisboa et al., 2018; Loozen et al., 2019; Furlanetto et al., 2021; Lu et al., 2021).

O P tem papel essencial na estrutura de moléculas do metabolismo fotossintético (ATP e NADPH), participa da síntese e translocação de açúcares nas plantas e da transferência de energia (ATP) (Malavolta, 2006; Prado, 2008; Bang et al., 2020). A deficiência do nutriente afeta as atividades fotossintéticas e a assimilação de CO₂, logo falta energia nos processos bioquímicos das plantas, por consequência o desenvolvimento vegetativo e do sistema radicular são afetados, com isso a produção de biomassa é reduzida, inclusive da cana-de-açúcar (Zambrosi et al., 2016). Os sintomas de deficiência de P são as colorações verde mais escuras nas folhas velhas, e em gramíneas coloração arroxeada ao longo da nervura, devido ao acúmulo de antocianina (Raij, 2017). Já para o nutriente K quando as plantas estão bem supridas, o fechamento e abertura dos estômatos ocorrem de forma adequada, a assimilação de CO₂ aumenta (incremento da taxa fotossintética) e a taxa de transpiração é reduzida (Rosseto, 2010). Além disso, o nutriente atua como ativador enzimático e na síntese e translocação de proteínas (Epstein, 1965). Por outro lado, plantas deficientes em K tem a fotossíntese afetada (Humbert, 1963) e apresentam o caule enfraquecido, devido a menor espessura da parede celular que causa colapso nos tecidos e acarreta acamamento. De acordo com a mobilidade do potássio na planta, a deficiência é observada em folhas mais velhas, em que as bordas ficam amareladas, consequentemente necrosadas.

Pesquisas mostram que a variabilidade do N nas culturas pode ser expressa por diferentes valores dos índices de vegetação, assim como é apresentado por Cilia et al., (2014) que ao utilizarem imagens hiperespectrais de dados aéreos para o mapeamento do nutriente na cultura do milho, observaram que as imagens podem ser usadas na detecção de áreas deficientes em nitrogênio. Nas regiões do espectro com menores valores dos índices de vegetação a produção de biomassa também foi menor. Com isso, os autores calcularam o índice de nutrição do nitrogênio (biomassa x teor de N na folha) e estimaram com precisão pelo índice de vegetação MTVI2 com um valor de $R^2 = 0.8$. Logo, a

pesquisa permitiu identificar plantas com diferentes teores de N e recomendar uma taxa de aplicação variável para a cultura. Maresma et al., (2016) ao avaliarem a aplicação de N na cultura do milho observaram que no tratamento sem aplicação do nutriente, a produtividade e os valores dos índices de vegetação foram baixos. Thompson et al., (2020) ao utilizarem um sensor multiespectral Micasense e calcularem o índice de vegetação NDRE, compararam a aplicação de N realizada de forma comercial com a aplicação baseada em dados do sensor. Com isso obtiveram um resultado de redução da quantidade de N aplicado em 31 Kg ha⁻¹ sem afetar o rendimento da cultura do milho.

No estudo da variabilidade de P e K nas lavouras, diversos pesquisadores atuaram com SR para melhor prever os comportamentos desses nutrientes. Como é o caso de Osborne et al., (2002) que ao utilizarem medidas de refletância hiperespectral por meio de um espectrômetro Analytical Spectral Devices obtiveram valores de comprimentos de onda nas regiões do infravermelho próximo e do azul que correlacionaram com o teor de P na cultura do milho. No estágio V6 da cultura, a refletância na região do NIR (730 a 930 nm) apresentou a melhor correlação, isso devido a um aumento no número de células menores por unidade de área foliar quando comparada a uma planta não estressada. Já para o estágio V8 os comprimentos de onda com melhor correlação para indicar o estresse de P foi na região visível do azul (440 a 445 nm), pois a planta sob a deficiência de P tem a produção de antocianina aumentada, consequentemente a folha apresenta coloração arroxeada e reflete no azul. Lisboa et al., (2018) ao utilizarem o índice de vegetação NDVI obtido por imagens de satélite (CBERS-4) e avaliarem a concentração de nutrientes no tecido foliar da cultura da cana-de-açúcar concluíram que o índice de vegetação é uma ferramenta útil. Foi observado que os valores maiores de NDVI indicaram maior concentração de nitrogênio e fósforo no tecido foliar (g kg⁻¹), os valores de correlação foram de $r = 0.56$ para o fósforo e $r = 0.46$ para o nitrogênio. Os autores concluíram que os resultados eram esperados, pois menores concentrações de nutrientes afetam os processos fotossintéticos das plantas interferindo na produtividade, consequentemente acarretando mudanças nas respostas espectrais.

Lu et al., (2021) ao avaliarem o acúmulo (teor do nutriente x biomassa) de K na cultura do arroz por meio do uso de um VANT encontraram resultados significativos entre o acúmulo do nutriente e os índices de vegetação, para ambos os índices RDVI e OSAVI o valor de $R^2 = 0.72$. Os autores identificaram que quando os teores de K nas plantas estão baixos, as refletâncias também são baixas, pelo fato de o K estar diretamente

ligado com a abertura e fechamento dos estômatos e os teores de água na planta. Severtson et al., (2016) ao avaliarem diferentes doses de K (0, 50, 100 e 400 Kg ha⁻¹) em canola com o monitoramento de imagens multiespectrais observaram que as parcelas deficientes em K as plantas apresentaram um menor desenvolvimento, consequentemente menor produtividade e menor valor de NDVI, já as parcelas suficientes em K, houve um melhor desenvolvimento das plantas, consequentemente produtividade e valor de NDVI superiores. Ou seja, as imagens de VANT tem potencial para estudo da variabilidade de nutrientes. Furlanetto et al., (2021) ao monitorarem o K na cultura do milho por meio de um sensor multiespectral, utilizaram de três tratamentos de K no solo, sendo definidos como deficiência acentuada de K, deficiência de K e fornecimento adequado de K. As avaliações com o sensor para os cálculos dos índices de vegetação foram nos estádios fenológicos V7 (sétima folha) e V12 (décima segunda folha). Os resultados mostraram que os índices de vegetação foram significativos na diferenciação das áreas com deficiência acentuada e teor adequado do nutriente no solo, e a época mais adequada de avaliação foi em V12, pois os índices de vegetação ao serem correlacionados com os teores de K na folha apresentaram valores de $R^2 > 0.7$, GRVI ($R^2 = 0.72$) e RVI ($R^2 = 0.71$). Com os resultados obtidos a pesquisa mostrou que é possível identificar a variabilidade do nutriente no solo e na planta e estimar os teores de K com o uso de índices de vegetação. Pelo exposto, o SR utilizando imagens de sensores possibilitam quantificar a variabilidade espacial e temporal da produtividade das culturas, dos teores de nutrientes no solo e nas plantas, a fim de compreender a variabilidade, e posteriormente realizar um manejo adequado para cada zona de manejo.

3) Material e métodos

3.1) Área de estudo

O experimento foi conduzido em uma área de cultivo de cana-de-açúcar, sob Latossolo Vermelho Distroférrico (Embrapa, 2018) (21°22'56.62''S; 47°57'19.53''), localizada no município de Pradópolis – SP. A variedade cultivada foi a RB 85-5156 em 1º corte ou cana planta e 2º corte ou 1ª soca. O plantio da cultura foi realizado em janeiro de 2018, e a colheita da cana planta em 04/06/2019 (plantio de dois verões), posteriormente o experimento também foi conduzido ao longo da safra 2019/2020 com a colheita da cana soca no período de 07/05/2020 a 25/05/2020 em uma área de 44 hectares.

No manejo da área foram realizados os seguintes tratos culturais, em que antes do plantio a área foi dessecada com o herbicida Glifosato, posteriormente o preparo de solo

da área consistiu na aplicação de 2 toneladas de calcário, em seguida foram realizadas a operação de eliminação de soqueira, subsolagem e gradagem. Na operação do plantio foram aplicados 500 Kg ha⁻¹ do fertilizante formulado 09 – 25 – 25 (45 Kg de N + 125 Kg de P₂O₅ + 125 K₂O), além disso foram aplicados os inseticidas: Regente Duo (Fipronil + Alfacipermetrina) e Altacor (Clorantraniliprole). Quanto aos tratos culturais na cana planta foram utilizados os herbicidas pré-emergentes: Combine (Tebutiuron) e Diuron (Diuron) e no controle de pragas o inseticida: Altacor (Clorantraniliprole). Logo após o primeiro corte, na primeira soca foi realizada a operação de corte de soqueira para a aplicação do inseticida Regente Duo (Fipronil + Alfacipermetrina), posteriormente foram aplicados os corretivos e adubações, os quais foram 1 tonelada de calcário, 15 toneladas de torta de filtro e 25 m³ ha⁻¹ de vinhaça, logo após o herbicida pré-emergente: Combine (Tebutiuron), e ao longo do desenvolvimento da cultura o inseticida: Altacor (Clorantraniliprole).

O clima da região segundo a classificação de Koppen é Cwa com verão quente e úmido e inverno frio e seco, com uma média de precipitação anual de 1300 – 1600 mm (Alvares et al., 2014). Para o ano de 2018 a precipitação anual foi de 1060 mm, em 2019 foi de 1166 mm e 2020 foi de 1683 mm. No primeiro ano de avaliação do experimento a precipitação acumulada do plantio em janeiro de 2018 até a colheita em 04/06/2019 foi de 1698 mm. Para o segundo ano de condução do experimento que foi a partir da colheita da cana planta até a colheita da cana soca em 07/05/2020 a precipitação foi de 1248 mm (Figura 1).




Figura 1 – Gráfico de precipitação ao longo dos anos de 2018, 2019 e 2020 e as respectivas operações de plantio e colheita.

3.2) Sensoriamento remoto

3.2.1) Aquisição das imagens

As imagens de refletância espectral foram obtidas no primeiro ano de desenvolvimento do experimento na data que antecedeu a colheita da cultura, no dia 03/06/2019 para a safra 2018/2019. Logo, na safra 2019/2020 foram adquiridas seis imagens ao longo do ciclo da cana-de-açúcar em que as respectivas datas estão na tabela abaixo (Tabela 1).

Tabela 1 – Aquisição das imagens ao longo do ciclo da cultura na safra 2019/2020.

Imagem	Data	Safra	Dias Após Colheita
1	14/10/2019	2019/2020	133
2	17/12/2019	2019/2020	197
3	14/01/2020	2019/2020	225
4	12/02/2020	2019/2020	254
5	27/03/2020	2019/2020	298
6	07/05/2020	2019/2020	339

A aquisição das imagens foi por meio de uma câmera multiespectral (Micasense®) embarcada em um VANT (DJI Matrice 100). Os voos foram realizados em uma altura de 120 m, com condições climáticas adequadas, geralmente no período da manhã sem a presença de nuvens, no entanto o sensor multiespectral foi calibrado antes de cada voo com a utilização de um painel calibrador de refletância. A sobreposição utilizada na obtenção das imagens foi de 75% lateral e 75% frontal para a obtenção de uma resolução de 0,08 m por pixel. As imagens de refletância, foram adquiridas nas diferentes bandas do espectro (Blue: 475 nm; Green: 560 nm; Red: 668 nm; RedEdge: 717 nm e Nir: 840 nm), posteriormente as imagens de refletância passaram pelo processamento por meio do software Pix4D para a obtenção dos mosaicos, e por fim foram utilizadas para calcular os índices de vegetação. Calculado os índices de vegetação, os valores foram escalonados com base em quartis para a identificação mais precisa da variabilidade da refletância das plantas (Martínez-Casasnovas et al., 2018). Em seguida, de acordo com a refletância do espectro foram classificadas as possíveis zonas de manejo ou zonas de diferentes potenciais, em que locais que apresentaram valores superiores para os índices de vegetação foram consideradas regiões de potencial produtivo superior, nos locais em que os valores dos pixels apresentaram valores intermediários os locais foram classificados como regiões de médio potencial produtivo, por conseguinte as regiões com valores de pixels inferiores foram classificadas como zonas de baixo potencial produtivo.




Figura 2 – Pontos de coletas de amostras de solo e plantas nas respectivas zonas de manejo, identificadas a partir da classificação dos diferentes valores de refletância do espectro da imagem.

3.2.2) Índices de vegetação

Neste estudo foram calculados 6 índices de vegetação, os quais mostraram resultados satisfatórios para análises agrícolas, delineamento de zonas de manejo e variabilidade de atributos químicos de solo e planta (Bendig et al., 2015; Ashapure et al., 2019; Yeom et al., 2019; Furlanetto et al., 2021; Denora et al., 2022). Destes, o índice de vegetação GRVI foi calculado com a utilização de bandas do espectro do visível (Red e Green) e os demais índices de vegetação utilizaram a banda do NIR ou infravermelho próximo (Tabela 2).

Tabela 2 – Lista dos índices de vegetação extraídos do sensor multiespectral.

Bandas	Índices de Vegetação	Fórmulas	Referência
RGB	GRVI (Índice de Vegetação Verde - Vermelho)	$(G - R)/(G + R)$	Tucker et al., (1979)
	NDVI (Índice de Vegetação por Diferença Normalizada)	$(Nir - R)/(Nir + R)$	Rouse et al., (1974)
	NDRE (Índice Red Edge por Diferença Normalizada)	$(Nir - RE)/(Nir + RE)$	Barnes et al., (2000)
NIR	GNDVI (Índice de Vegetação por Diferença Normalizada - Green)	$(Nir - G)/(Nir + G)$	Gitelson et al., (2003)
	SAVI (Índice de Vegetação Ajustado ao Solo)	$(1.5 * (Nir - R))/(Nir + R + 0.5)$	Roundeaux et al., (1996)
	RVI (Relação entre Infravermelho e Vermelho)	Nir/Red	Birth et al., (1968)

3.2.3) Extração dos valores de pixels

Os valores dos pixels dos índices de vegetação foram extraídos das imagens por ferramentas do software Qgis Desktop 3.16.3. O método consistiu na criação de um polígono sob cada um dos pontos de amostragens georreferenciados (Figura 2) para a

realização da leitura dos valores de 4.000 pixels. A extração dos valores de pixels foi realizada de forma manual (Bruce et al., 2020), em que por meio dos intervalos de valores de pixels foram observados os valores referentes a vegetação e calculado a média em cada ponto de coleta das respectivas zonas de manejo.

3.3) Amostragem de solo e plantas

Ao calcular os índices de vegetação, escalonar os valores de pixels em quartis para a identificação da variabilidade da refletância das plantas e definir as zonas de potencial produtivo, foram realizadas amostragens de solo e planta em 10 pontos georreferenciados em cada uma das zonas consideradas homogêneas para a avaliação do estado nutricional das plantas, da fertilidade do solo e da textura do solo (Figura 2).

Precedendo a colheita, foram realizadas amostragens de plantas em cada um dos pontos georreferenciados onde foram coletadas as amostras de solo. As plantas foram coletadas em 1,5 m da linha da cana-de-açúcar, posteriormente foram separadas em diferentes partes (ponteiro, colmo e palha), as quais foram pesadas individualmente. Em seguida, uma subamostra de cada uma das partes foi separada e levada ao laboratório, visando a determinação de matéria seca e dos teores de nutrientes. A massa de colmos foi utilizada para estimar a produtividade da cultura (Mg ha^{-1}). Posteriormente, após separadas, as amostras foram submetidas à análise química para determinação dos teores de nutrientes (Malavolta, 1997). Com os dados de matéria seca e teores dos nutrientes, foram calculados os valores de exportação (matéria seca de colmo x teor do nutriente no colmo – Kg ha^{-1}) e extração ((matéria seca de ponteiro x teor do nutriente no ponteiro) + (matéria seca de palha x teor do nutriente na palha) + (matéria seca do colmo x teor do nutriente no colmo) – (Kg ha^{-1})) para a avaliação em cada zona de manejo.

Após as colheitas foram coletadas as amostras de solo nas camadas de 0.0 – 0.2 e 0.2 – 0.4 m, e posteriormente foram secadas e passadas em peneiras de 2 mm, logo foram submetidas a análise química para a determinação dos valores de pH em CaCl_2 e teores de P, K, Ca, Mg e H + Al, de acordo com Raij et al., (2001). Com os resultados foram calculados a capacidade de troca de cátions do solo (CTC) e saturação por bases (V%). Além disso, as amostras de solo foram submetidas a análises texturais para a avaliação dos teores de silte, argila e areia em cada zona de manejo, sendo classificadas de acordo com a Embrapa (2018).

3.4) Mapa temático da produtividade (Mg ha⁻¹)

Para a aquisição dos dados de produtividade foi utilizada uma balança com quatro células de carga acoplada no elevador da colhedora de cana-de-açúcar, em que foi mensurado o fluxo de cana crua que passava pela esteira do elevador da colhedora. Além disso, para a regulação da balança foi utilizado um sensor de inclinação do elevador para a leitura correta do fluxo de cana, um medidor de fluxo da esteira, gps, monitor e por fim um transbordo com células de carga, o qual foi utilizado para aferição e obtenção de forma precisa dos dados da balança acoplada na colhedora.

Além da obtenção dos dados de produtividade, na colhedora foi instalado um Sistema de Posicionamento Global Diferencial (DGPS) que permitiu coletar todas as coordenadas em cada ponto de leitura da balança, posteriormente permitiu a elaboração de um mapa digital com os dados de produtividade e as respectivas coordenadas. Para a elaboração do mapa de produtividade, os dados foram analisados por meio de distribuição com a criação de um histograma no software Qgis Desktop 3.16.3, em seguida foram excluídos os dados discrepantes, ou seja, dados não reais. Logo, foi utilizada a metodologia de Menegatti & Molin (2002) com a seguinte fórmula: Limite Superior = Quartil Superior + 1.5*Amplitude Interquartílica e Limite Inferior = Quartil Inferior - 1.5*Amplitude Interquartílica. Posteriormente, os dados foram submetidos a interpolação por Krigagem no Plugin Smart-Map, ferramenta do software Qgis, para a obtenção do mapa temático referente a variabilidade espacial da produtividade da cana-de-açúcar na safra 2019/20.

3.5) Definição das zonas de manejo

Para a delimitação das respectivas zonas de manejo foram utilizados os mapas dos índices de vegetação adquiridos ao longo dos ciclos da cultura e o mapa de produtividade. Os mapas dos índices de vegetação passaram pelo processo de interpolação, pois houve necessidade de os tamanhos dos pixels dos índices de vegetação apresentarem o mesmo tamanho dos pixels obtidos no mapa de produtividade (10 m x 10 m). Logo após, os mapas foram adicionados ao Plugin Smart-Map no software Qgis 3.16.3, e por meio do método fuzzy k-means (Bezdek et al., 1984) foi determinado o número adequado de classes ou zonas de manejo. Para a obtenção do número ótimo de classes foi determinado o valor de dois índices, o índice de Performance Fuzzy (FPI) e o índice de Entropia de Partição Modificada (MPE) (Song et al., 2009). No caso, o FPI é uma medida do grau de imprecisão gerado por um número específico de classes, e o MPE estima o grau de

desorganização criado por um determinado número de classes. Os valores dos índices variam de 0 a 1, em que valores próximos de 0 indicam zonas ou classes de pouco compartilhamento ou um grau mais acentuado de diferença entre elas, por outro lado valores próximos a 1 indicam classes que não apresentam diferenças, ou que não são distintas, apresentando alto grau de compartilhamento ou semelhança entre elas. Com isso, o número ideal de zonas de manejo é quando os valores dos índices são mínimos ou próximos de 0, pois representam uma diferença mais acentuada entre as classes ou zonas. Sendo assim, a partir dos valores dos índices FPI e MPE foram obtidas as zonas de manejo para cada índice de vegetação. Para cada índice de vegetação em combinação com o mapa de produtividade foram calculados 96 valores dos índices FPI e MPE, as quais levaram em consideração as imagens adquiridas ao longo do ciclo, posteriormente para cada índice foram observados os valores mínimos dos índices FPI e MPE, em seguida para cada valor mínimo dos índices foram geradas as imagens de classes ou zonas de manejo. Além disso, para cada zona de manejo foi realizada a análise estatística por meio de uma análise de variância (ANOVA) para observação das diferenças entre as produtividades, e se caso as diferentes zonas diferem estatisticamente.

3.6) Estatística dos dados de sensoriamento remoto

Para os dados de amostragens de plantas foram realizadas as análises descritivas, a qual consistiu nos valores das médias, do desvio padrão e do coeficiente de variação. Já para os valores dos índices de vegetação obtidos por meio do sensoriamento remoto a fim de identificar os parâmetros agrônômicos, tais como teores de nutrientes, exportação e extração foram calculadas as análises de regressão, por meio dos valores dos coeficientes de determinação (R^2).

4) Resultados

4.1) Variabilidade espacial de refletância dos índices de vegetação na cultura da cana-de-açúcar na safra 2018/2019

Na figura 4 são apresentados os mapas dos índices de vegetação obtidos na colheita da safra 2018/2019, os quais foram utilizados para identificar inicialmente as respectivas zonas de manejo.




Figura 4 – Imagens de sensoriamento remoto obtidas na safra 2018/19. As respectivas imagens correspondem aos determinados índices de vegetação. GRVI, NDVI, NDRE, GNDVI, SAVI e RVI.

Com a aquisição das imagens de sensoriamento remoto foram calculadas as médias dos valores de pixels para cada índice de vegetação nas respectivas zonas de manejo (tabela 3). Os valores dos índices de vegetação para a zona de manejo de alto potencial produtivo apresentaram valores superiores, em que o GRVI apresentou um valor superior em 36%, o NDVI em 6%, NDRE em 12%, GNDVI em 4%, SAVI em 10% e RVI em 24% quando comparados com as médias dos índices de vegetação das zonas de

manejo de médio potencial produtivo. Ao comparar os valores dos índices de vegetação da zona de manejo de alto potencial produtivo com a zona de baixo potencial produtivo os valores foram superiores em 64% para o GRVI, 12% para o NDVI, em 20% para o NDRE, em 8% para o GNDVI, em 25% para o SAVI e em 29% para o RVI, ou seja, os valores obtidos com os índices de vegetação foram superiores para a zona de alto potencial produtivo, intermediários para a zona de médio potencial, e inferiores para a zona de baixo potencial agrícola.

Tabela 3 – Valores das médias dos índices de vegetação para cada zona de manejo.

Médias dos Índices de Vegetação em cada Zona de Manejo									
Índices de Vegetação	Zona de Alto Potencial Produtivo			Zona de Médio Potencial Produtivo			Zona de Baixo Potencial Produtivo		
	Média	± DP	CV (%)	Média	± DP	CV (%)	Média	± DP	CV (%)
GRVI	0.1750	± 0.0069	4	0.1126	± 0.0191	17	0.6360	± 0.0132	21
NDVI	0.8276	± 0.0046	1	0.7806	± 0.0098	1	0.7341	± 0.0122	2
NDRE	0.4670	± 0.0052	1	0.4146	± 0.0069	2	0.3774	± 0.0083	2
GNDVI	0.7649	± 0.0044	1	0.7352	± 0.0033	0	0.7057	± 0.0076	1
SAVI	0.5954	± 0.0183	3	0.5392	± 0.0066	1	0.4472	± 0.0280	6
RVI	11.036	± 0.3559	3	8.4722	± 0.4136	4	6.7430	± 0.3425	5

De acordo com a diferença de refletância do espectro das imagens e dos diferentes valores dos índices de vegetação foram coletadas as amostras de plantas referente a cada zona de manejo para obtenção da produtividade estimada (Tabela 4). Na zona de manejo de alto potencial produtivo, a produtividade estimada foi superior em 6% e 26% quando comparada com a zona manejo de médio e baixo potencial produtivo. No caso, os valores superiores de refletância indicaram locais de melhores potenciais produtivos, por outro lado locais em que os valores dos índices de vegetação foram baixos, a produtividade também apresentou valores inferiores.

Tabela 4 – Valores produtividade estimada para cada zona de manejo.

	Zona de Alto Potencial Produtivo			Zona de Médio Potencial Produtivo			Zona de Baixo Potencial Produtivo		
	Média	± DP	CV (%)	Média	± DP	CV (%)	Média	± DP	CV (%)
Produtividade Estimada (Mg ha ⁻¹)	114	± 23	22	107	± 24	23	87	± 10	12

Ao realizar a análise estatística por meio de uma análise de variância com Teste Tukey a 5% de probabilidade para a produtividade estimada, foi identificado que na safra

2018/2019 que a zona de manejo de maior potencial produtivo não apresentou diferença estatística quando comparada a zona de manejo de médio potencial produtivo. Por outro lado, quando comparadas estatisticamente com a zona de manejo de baixo potencial produtivo houve diferença para a produtividade estimada (Tabela 5).

Tabela 5 – Análise estatística entre as zonas de manejo.

Zonas de Manejo	Produtividade Estimada (Mg ha⁻¹)
Alto Potencial Produtivo	114 a
Médio Potencial Produtivo	107 ab
Baixo Potencial Produtivo	87 b
DMS (5%)	23.7

4.2) Variabilidade espacial e temporal da refletância dos índices de vegetação da cultura da cana-de-açúcar na safra 2019/2020

Ao longo do ciclo da cana-de-açúcar na safra 2019/2020 foram adquiridas seis imagens de sensoriamento remoto com a finalidade de avaliar a variabilidade espacial e temporal da cultura (figura 5), imagens as quais foram identificadas de acordo com o número de dias após a colheita, ou seja, após a colheita da safra 2018/2019. Com a definição das zonas de manejo por meio das diferentes refletâncias do espectro, os valores das médias dos índices de vegetação foram extraídos para cada zona de manejo ao longo da safra de 2019/20 com a finalidade de compreender a variabilidade temporal ao longo do ciclo (tabela 6).

Para a zona de manejo de alto potencial produtivo os valores dos índices de vegetação ao longo do ciclo da cana-de-açúcar foram superiores para todos os índices de vegetação, já os valores dos índices de vegetação para a zona de manejo de médio potencial produtivo ficaram em limites intermediários dentro dos valores dos comportamentos espectrais, e consequentemente para a zona de baixo potencial produtivo os valores dos índices foram inferiores. Para o índice de vegetação GRVI a zona de manejo de alto potencial produtivo apresentou valores superiores do índice ao longo do ciclo, já ao comparar as zonas de médio e baixo potencial produtivo, a partir da imagem obtida com 254 dias após a colheita ou do mês de fevereiro que ocorreu a maior diferença entre os valores do índice para a definição das zonas de manejo, com uma diferença de 32%. Para o índice de vegetação NDVI o comportamento espectral foi similar para a zona de alto potencial, porém a zona de manejo de médio e baixo potencial se diferenciaram

com maior intensidade nos valores do espectro a partir da imagem adquirida aos 254 DAC ou do mês de fevereiro de 2020, em torno de 5%.




Figura 5 – Imagens de NDVI da variabilidade espacial e temporal da cana-de-açúcar. As imagens foram obtidas no início do desenvolvimento da cultura até a colheita. A imagens foram adquiridas nas seguintes datas: 14/10/2019 (133 DAC), 17/12/2019 (197 DAC), 14/01/2020 (225 DAC), 12/02/2020 (254 DAC), 27/03/2020 (298 DAC) e 07/05/2020 (339 DAC).

Para o NDRE o comportamento espectral é semelhante ao NDVI. Para o GNDVI, a zona de maior potencial manteve-se ao longo do ciclo da cultura com os valores superiores, e a partir da imagem adquirida aos 298 DAC ou do mês de março que a zona de médio e baixo potencial apresentaram 4% de diferença nos valores do índice. Para o índice de vegetação SAVI a diferença no espectro entre a zona de manejo de alto potencial para a de médio potencial foi em torno de 10%, já para a zona de médio potencial em comparação com a de baixo potencial foi de 13%, em que essas diferenças no espectro foram a partir da imagem adquirida aos 133 DAC ou do mês de outubro de 2019. Para o RVI, a zona de alto potencial apresentou valores superiores do índice ao longo de todo o ciclo, já a zona de médio e de baixo potencial apresentaram um intervalo maior de diferença a partir da imagem adquirida aos 254 DAC, em torno de 21%. Na figura 6 é representada a tabela 6 em forma de gráfico para visualização dos comportamentos espectrais da cultura da cana-de-açúcar ao longo do ciclo em cada zona de manejo, podendo observar que para a zona de manejo de alto potencial produtivo os valores dos índices são superiores, já para a zona de manejo de potencial médio os valores são intermediários, consequentemente para a zona de baixo potencial os valores são mínimos.

Tabela 6 – Valores das médias dos índices de vegetação ao longo do ciclo da cultura para cada zona de manejo.

Imagens	Zonas de Manejo	Valores de Índices de Vegetação					
		GRVI	NDVI	NDRE	GNDVI	SAVI	RVI
133 DAC	Baixo Potencial	-0.1388	0.3919	0.2334	0.4979	0.2354	2.2500
	Médio Potencial	-0.1671	0.3947	0.2600	0.5208	0.2678	2.2604
	Alto Potencial	-0.1440	0.4422	0.2901	0.5441	0.2991	2.5266
197 DAC	Baixo Potencial	0.0492	0.6652	0.3855	0.6375	0.3561	4.9962
	Médio Potencial	0.0563	0.6695	0.3810	0.6374	0.4127	5.0600
	Alto Potencial	0.1047	0.7204	0.4227	0.6649	0.4787	6.1489
225 DAC	Baixo Potencial	0.4246	0.8506	0.5653	0.6700	0.3046	12.5012
	Médio Potencial	0.4280	0.8574	0.5778	0.6802	0.3795	13.0596
	Alto Potencial	0.4695	0.8822	0.6054	0.7056	0.4486	15.9731
254 DAC	Baixo Potencial	0.1943	0.8066	0.4969	0.7288	0.6219	9.5184
	Médio Potencial	0.2834	0.8448	0.5215	0.7400	0.6429	11.9872
	Alto Potencial	0.3415	0.8719	0.5581	0.7563	0.6749	14.6807
298 DAC	Baixo Potencial	0.1465	0.7540	0.4255	0.6851	0.4179	7.1732
	Médio Potencial	0.2137	0.7999	0.4546	0.7084	0.5893	9.0272
	Alto Potencial	0.2923	0.8460	0.4990	0.7363	0.6651	11.9899
339 DAC	Baixo Potencial	0.1919	0.7984	0.4869	0.7163	0.4023	8.9399
	Médio Potencial	0.2493	0.8396	0.5210	0.7465	0.5770	11.4693
	Alto Potencial	0.3118	0.8861	0.5803	0.7936	0.6943	16.5720




Figura 6 – Valores das médias dos índices de vegetação ao longo da safra 2019/20, a fim de observar a diferença de comportamento no espectro da cultura da cana-de-açúcar para cada zona de manejo.

4.3) Variabilidade espacial da refletância dos índices de vegetação da cultura da cana-de-açúcar na safra 2019/2020

Na figura 7 estão apresentados os mapas dos índices de vegetação obtidos na data da colheita da safra 2019/2020, em que os índices de vegetação por meio das diferenças nas refletâncias permitiram identificar as diferentes zonas de manejo e direcionar as coletas de solo e planta.




Figura 7 – Mapas dos índices de vegetação obtidos na data da colheita para a identificação da variabilidade espacial e temporal da produtividade da cana-de-açúcar.

Na tabela 7 estão apresentados os valores dos índices de vegetação na data de colheita da safra 2019/2020. Para os valores dos índices de vegetação a zona de alto potencial produtivo apresentou valores superiores para todos os índices de vegetação. No caso do GRVI o valor foi superior em 21%, para o NDVI em 6%, para o NDRE em 11%, para o GNDVI em 6%, para o SAVI em 17% e para o RVI em 31% quando comparada a zona de médio potencial produtivo, já ao comparar com a zona de baixo potencial produtivo os valores diferiram em 29% para o GRVI, em 10% para o NDVI, em 17%

para o NDRE, em 10% para o GNDVI, em 43% para o SAVI e 47% para o RVI. Por meio dos valores dos índices foram realizadas as coletas de plantas para a determinação da produtividade estimada (tabela 8).

Tabela 7 – Valores das médias dos índices de vegetação para cada zona de manejo na época da colheita da safra 2019/20.

Médias dos Índices de Vegetação em cada Zona de Manejo									
Índices de Vegetação	Zona de Alto Potencial Produtivo			Zona de Médio Potencial Produtivo			Zona de Baixo Potencial Produtivo		
	Média	± DP	CV (%)	Média	± DP	CV (%)	Média	± DP	CV (%)
GRVI	0.3118	± 0.0085	3	0.2493	± 0.0093	4	0.1919	± 0.0082	4
NDVI	0.8861	± 0.0030	0.3	0.8396	± 0.0029	0.3	0.7984	± 0.0099	1.2
NDRE	0.5803	± 0.0062	1.1	0.5210	± 0.0076	1.5	0.4869	± 0.0118	2.4
GNDVI	0.7936	± 0.0041	0.5	0.7465	± 0.0065	0.9	0.7163	± 0.0096	1.3
SAVI	0.6943	± 0.0123	1.8	0.5770	± 0.0211	3.7	0.4023	± 0.0131	3.2
RVI	16.572	± 0.4745	3	11.469	± 0.2218	2	8.9399	± 0.4693	5

Para a zona de alto potencial produtivo a produtividade estimada foi superior em 25% quando comparada a zona de médio potencial, e 50% em relação a zona de baixo potencial produtivo. Logo, na tabela 9 é apresentada a análise de variância na identificação da diferença estatística da produtividade estimada entre as zonas de manejo. Com o resultado estatístico apresentado é observado que há diferença de produtividade entre as zonas de manejo, e com isso as diferentes zonas de manejo podem ser manejadas de acordo com o potencial de cada uma delas

Tabela 8 – Valores dos parâmetros agrônômicos obtidos com o levantamento de plantas nas áreas indicadas como diferentes zonas de manejo.

	Zona de Alto Potencial Produtivo		Zona de Médio Potencial Produtivo		Zona de Baixo Potencial Produtivo	
	Média ± DP	CV (%)	Média ± DP	CV (%)	Média ± DP	CV (%)
Produtividade Estimada (Mg ha ⁻¹)	126 ± 10	8	97 ± 14	15	62 ± 6	10

Tabela 9 – Análise estatística entre as zonas de manejo.

Zonas de Manejo	Produtividade Estimada (Mg ha ⁻¹)
Alto Potencial Produtivo	126 a
Médio Potencial Produtivo	97 b
Baixo Potencial Produtivo	62 c
DMS (5%)	24

4.4) Mapa de Produtividade

Por meio dos dados de produtividade gerados a partir do monitor de colheita foi possível a obtenção do mapa temático da produtividade da cana-de-açúcar na safra 2019/2020 (Figura 8).




Figura 8 – Mapa temático da produtividade da cultura da cana-de-açúcar e os diferentes valores de produtividade (Mg ha^{-1}).

Na tabela 10 estão apresentados os valores médios da produtividade da cana-de-açúcar (Mg ha^{-1}) para cada zona de manejo. A zona de alto potencial produtivo foi superior em 20% quando comparada a zona de médio potencial produtivo e 26% em relação a zona de baixo potencial produtivo. Além disso, as zonas de manejo se diferenciaram estatisticamente

Tabela 10 – Análise estatística da produtividade real entre as diferentes zonas de manejo.

Zonas de Manejo	Produtividade Real (t ha^{-1})
Alto Potencial Produtivo	103 a
Médio Potencial Produtivo	82 b
Baixo Potencial Produtivo	76 c
DMS (5%)	1,8

4.5) Delimitação das zonas de manejo

Para a delimitação das zonas de manejo foram utilizados o mapa de produtividade em combinação com os mapas oriundos dos índices de vegetação ao longo do ciclo da cultura. No caso do índice de vegetação GRVI a combinação mais precisa para a delimitação das zonas de manejo foi a combinação entre o mapa de produtividade e a imagem adquirida aos 133 dias após a colheita, em que o índice FPI e MPE foram os mais próximos de 0 (FPI = 0.084 e o MPE = 0.102). Para o índice de vegetação NDVI os valores de FPI e MPE foram 0.078 e 0.08 em que a imagem adquirida com 254 dias após a colheita foi mais precisa. Para o NDRE a imagem adquirida aos 133 dias após a colheita foi a mais precisa entre as 96 combinações, pois apresentou um FPI de 0.083 e um MPE de 0.088. Já para os índices de vegetação GNDVI e SAVI as imagens adquiridas aos 298 dias após a colheita foram as mais precisas, com o valor de FPI de 0.089 e 0.086, e o valor de MPE de 0.097 e 0.093. Quanto ao índice RVI foi o qual apresentou os valores mais próximos de 0, em que o FPI = 0.051 e MPE = 0.066, sendo assim entre os índices de vegetação o RVI foi o qual apresentou resultado superior, ou seja para a delimitação de zonas de manejo em conjunto com o mapa de produtividade o índice foi o mais preciso, apresentando valores próximos de 0, indicando que a delimitação das zonas de manejo por meio do uso do RVI é a de mais precisa delimitação e com diferenças mais acentuadas das diferentes classes. Contudo para a validação mais precisa do índice foi preciso obter 3 imagens, a imagem obtida na colheita da safra 2018/2019 (Colheita 1), a imagem da colheita da safra 2019/2020 (339 DAC ou Colh. 2) e a imagem de 225 dias após a colheita 1, por mais que em relação aos outros índices foram necessários mais aquisição de imagens, o resultado com o RVI é o mais preciso na delimitação de zonas de manejo.

Tabela 11 – Valores de FPI (Índice de Performance Fuzzy) e MPE (Índice de Entropia de Partição Modificada) e número de classes das combinações entre os índices de vegetação e o mapa de produtividade.

Índices de Vegetação x Mapa de Produtividade						
Índices	Imagens - Dias Após a Colheita			FPI	MPE	Classes
GRVI	133			0.084	0.102	3
NDVI	254			0.078	0.08	3
NDRE	133			0.083	0.088	3
GNDVI	298			0.089	0.097	3
SAVI	298			0.086	0.093	3
RVI	Colheita 1	Colheita 2	225	0.051	0.066	3

Para todas as combinações o número de classes ideal gerado por meio da técnica Fuzzy k-means foram 3 classes, com esse resultado por meio do uso desses índices de vegetação é possível identificar a variabilidade da área de cana-de-açúcar e delimitar as respectivas zonas de manejo em zona de manejo de alto, médio e baixo potencial produtivo. Nas figuras 9, 10, 11, 12, 13 e 14 são apresentadas as respectivas zonas de manejo definidas a partir dos índices de vegetação em combinação com o mapa de produtividade.




Figura 9 – Definição das zonas de manejo entre o mapa de produtividade e o índice de vegetação GRVI.




Figura 10 – Definição das zonas de manejo entre o mapa de produtividade e o índice de vegetação NDVI.




Figura 11 – Definição das zonas de manejo entre o mapa de produtividade e o índice de vegetação NDRE.




Figura 12 – Definição das zonas de manejo entre o mapa de produtividade e o índice de vegetação GNDVI.




Figura 13 – Definição das zonas de manejo entre o mapa de produtividade e o índice de vegetação SAVI.




Figura 14 – Definição das zonas de manejo entre o mapa de produtividade e o índice de vegetação RVI.

4.6) Variabilidade dos teores de fósforo e potássio no solo e na planta

4.6.1) Análise química da fertilidade dos solos nas diferentes zonas de manejo

Na tabela 12 estão apresentados os valores dos atributos químicos do solo coletados após a colheita da safra 2018/2019. Na interpretação dos resultados das

amostragens de solo foi utilizada a metodologia de Raij (2017). Os valores de pH para todas as zonas de manejo estão em torno de 6, indicando que o solo está corrigido por apresentar uma acidez baixa. Os teores de fósforo no solo estão em níveis altos, no entanto os teores da zona de alto potencial estão próximos ao limite inferior da faixa do teor alto de fósforo. Para o teor de potássio, todas as zonas de manejo apresentaram teores baixos do nutriente no solo. Quanto aos teores de cálcio e magnésio e a saturação por base estão adequados.

Tabela 12 – Teores dos atributos químicos do solo nas diferentes zonas de manejo para a cultura da cana-de-açúcar na safra 2018/2019.

Zonas de Manejo									
<u>Zona de Alto Potencial Produtivo</u>									
Prof.	pH	P (resina)	K	Ca	Mg	H+Al	SB	CTC	V
(m)	(CaCl ₂)	mg dm ⁻³	mmolc dm ⁻³						%
0.0 - 0.2	6	53	1.2	46	22	11	69	80	86
0.2 - 0.4	5.9	46	1.3	33	15	14	49	63	78
<u>Zona de Médio Potencial Produtivo</u>									
0.0 - 0.2	6.2	74	1.2	41	18	12	60	72	83
0.2 - 0.4	6.2	67	1	35	16	11	52	63	82
<u>Zona de Baixo Potencial Produtivo</u>									
0.0 - 0.2	6.4	76	1.1	40	18	11	59	70	84
0.2 - 0.4	6.4	60	1	48	26	11	75	86	87

Na tabela 13 estão os valores dos atributos químicos do solo referentes a safra 2019/2020. A acidez do solo foi considerada baixa, devido aos valores de pH, os quais indicaram que o solo está corrigido para ambas as zonas de manejo. Para o teor de fósforo a zona de manejo de alto potencial agrícola apresentou limitação, em que os teores foram considerados baixos em ambas as profundidades. Os teores de fósforo para a zona de médio potencial produtivo apresentou adequado, em que os teores continuaram classificados como altos, e no caso para a zona de manejo de baixo potencial agrícola o teor de P no solo na camada de 0.0 – 0.2 m está adequado, já na camada de 0.2 – 0.4 m foi classificado como baixo. Para o teor de potássio no solo, ambas as zonas de manejo apresentaram teores médios na camada de 0.0 – 0.2 m e teores baixos na camada de 0.2 – 0.4 m. Quanto aos teores de cálcio e magnésio no solo ambas as zonas de manejo estão adequadas, e saturação por bases também.

Tabela 13 – Teores dos atributos químicos do solo nas diferentes zonas de manejo para a cultura da cana-de-açúcar na safra 2018/2019.

Zonas de Manejo									
<u>Zona de Alto Potencial Produtivo</u>									
Prof.	pH	P (resina)	K	Ca	Mg	H+Al	SB	CTC	V
(m)	(CaCl ₂)	mg dm ⁻³	mmolc dm ⁻³						%
0.0 - 0.2	6.8	34	2.9	33	14	9	50	59	84
0.2 - 0.4	6.5	30	1.5	29	12	13	43	56	77
<u>Zona de Médio Potencial Produtivo</u>									
0.0 - 0.2	6.5	77	2.5	42	18	10.4	63	73	86
0.2 - 0.4	6.4	57	1.5	32	14	10.3	48	58	82
<u>Zona de Baixo Potencial Produtivo</u>									
0.0 - 0.2	6.7	59	2.3	33.6	13.3	9.1	49	58	84
0.2 - 0.4	6.4	36	1.4	25.4	10	11.5	37	48	76

4.6.2) Variabilidade de fósforo e potássio nos tecidos vegetais

Na tabela 14 estão apresentados os dados dos teores de fósforo, exportação e extração do nutriente na safra 2018/2019. Para o teor do nutriente no colmo os valores nas zonas de alto e médio potencial produtivo foram similares, porém a zona de baixo potencial agrícola apresentou 50% a menos da quantidade de fósforo no colmo. Quanto ao teor total do nutriente as três zonas de manejo não apresentaram diferenças. Ao analisar a quantidade exportada e extraída do nutriente, a zona de médio potencial agrícola exportou e extraiu valores próximos a zona de alto potencial, no entanto a quantia exportada foi de 60% e a extraída de 55% quando comparada a zona de baixo potencial. Para o nutriente potássio os teores no colmo e os teores totais apresentaram quantidades próximas, porém a zona de alto e médio potencial produtivo exportaram e extraíram em média 32% e 38% a mais que a zona de baixo potencial produtivo. Na validação dos modelos de regressão para a avaliação da variabilidade de fósforo e potássio os coeficientes de determinação apresentaram valores de $R^2 < 0.5$, indicando que os índices de vegetação não foram significativos (tabela 16 e 17).

Tabela 14 – Valores dos teores totais de fósforo, dos teores do nutriente no colmo, exportação e extração do nutriente nas diferentes zonas de manejo.

Fósforo													
		Zona de Alto Potencial Produtivo				Zona de Médio Potencial Produtivo				Zona de Menor Potencial Produtivo			
		Média	±	DP	CV (%)	Média	±	DP	CV (%)	Média	±	DP	CV (%)
Teor no Colmo	(g Kg ⁻¹)	2.4	±	0.7	29	2.5	±	0.2	6	2.2	±	0.5	22
Teor Total		3.6	±	0.9	27	3.9	±	0.2	6	3.3	±	0.6	18
Exportação	(kg ha ⁻¹)	82	±	31	37	84	±	21	25	33	±	14	44
Extração		86	±	32	37	88	±	22	25	40	±	14	35

Tabela 15 – Valores dos teores totais de fósforo, dos teores do nutriente no colmo, exportação e extração do nutriente nas diferentes zonas de manejo.

Potássio													
		Zona de Alto Potencial Produtivo				Zona de Médio Potencial Produtivo				Zona de Menor Potencial Produtivo			
		Média	±	DP	CV (%)	Média	±	DP	CV (%)	Média	±	DP	CV (%)
Teor no Colmo	(g Kg ⁻¹)	10	±	2.7	25	11	±	2.3	20	9	±	0.8	9
Teor Total		26	±	3.3	13	26	±	2.6	10	25	±	2	8
Exportação	(kg ha ⁻¹)	390	±	81	20	382	±	122	32	243	±	45	18
Extração		425	±	94	22	422	±	127	30	290	±	42	15

Tabela 16 – Valores dos coeficientes de determinação (R²) entre os índices de vegetação e os teores de fósforo na cultura da cana-de-açúcar.

Fósforo				
Coeficiente de Determinação (R ²)				
Índices de Vegetação	Teor Total	Teor do colmo	Exportação	Extração
	(g kg ⁻¹)		(Kg ha ⁻¹)	
GRVI	0.02	0.18	0.28	0.27
NDVI	0.03	0.24	0.33	0.31
NDRE	0.02	0.20	0.28	0.27
GNDVI	0.03	0.26	0.33	0.30
SAVI	0.03	0.31	0.37	0.34
RVI	0.02	0.17	0.26	0.25

Tabela 17 – Valores dos coeficientes de determinação dos modelos de regressão entre os índices de vegetação e os teores de potássio em cana planta para a safra 2018/2019.

Potássio				
Coeficiente de Determinação (R^2)				
Índices de Vegetação	Teor Total	Teor do colmo	Exportação	Extração
	(g Kg ⁻¹)		(Kg ha ⁻¹)	
GRVI	0.05	0.05	0.24	0.24
NDVI	0.06	0.06	0.24	0.24
NDRE	0.05	0.05	0.20	0.21
GNDVI	0.07	0.07	0.23	0.22
SAVI	0.09	0.10	0.27	0.26
RVI	0.06	0.05	0.22	0.22

Na colheita da safra 2019/2020 foram analisados os teores dos nutrientes fósforo e potássio na cultura da cana-de-açúcar com a finalidade de avaliar a variabilidade do P e K na cultura. Na tabela 18 estão apresentados os teores de fósforo para as zonas de manejo, sendo notável que para os teores do nutriente no colmo e teores totais na planta os resultados foram similares. No entanto, quanto a exportação de fósforo no segundo corte da cana-de-açúcar foi observada que a zona de manejo de alto potencial exportou uma quantidade superior em 17% em relação a zona de médio potencial, e 48% em relação a zona de baixo potencial, isso devido a produtividade da zona de manejo de alto potencial que foi superior. Quanto a extração do nutriente, a zona de alto potencial produtivo utilizou de uma demanda maior de fósforo, em torno de 20% e 47% quando comparada a zona de médio e baixo potencial agrícola.

Tabela 18 – Teores de fósforo nas diferentes zonas de manejo na safra 2019/2020.

Fósforo							
		Zona de Alto		Zona de Médio		Zona de Baixo	
		Potencial Produtivo		Potencial Produtivo		Potencial Produtivo	
		Média ± DP	CV (%)	Média ± DP	CV (%)	Média ± DP	CV (%)
Teor no Colmo	(g Kg ⁻¹)	1 ± 0.3	27	1 ± 0.2	15	1.3 ± 0.2	20
Teor Total		3.1 ± 0.38	12	3.5 ± 0.36	10	3.5 ± 0.35	10
Exportação	(Kg ha ⁻¹)	48 ± 23	49	40 ± 13	31	25 ± 7	28
Extração		56 ± 23	41	45 ± 13	28	30 ± 8	26

Ao analisar os teores de potássio nas diferentes zonas de manejo (tabela 19), a fim de identificar a variabilidade do nutriente foi observado que a zona de alto potencial produtivo apresentou teores maiores no colmo, em torno de 13% quando comparada as demais zonas de manejo. Para o teor total do nutriente, a zona de maior potencial absorveu em torno de 7% e 14% quando comparada com a de médio potencial e baixo potencial produtivo. Quanto a exportação e extração de potássio, a zona de alto potencial produtivo foi superior em 38% e 60% quando comparada a zona de médio potencial produtivo, e em torno de 60% e 58% quando comparada a zona de baixo potencial.

Tabela 19 – Teores de potássio nas diferentes zonas de manejo na safra 2019/2020 na cultura da cana-de-açúcar.

		Potássio					
		Zona de Alto Potencial Produtivo		Zona de Médio Potencial Produtivo		Zona de Baixo Potencial Produtivo	
		Média ± DP	CV (%)	Média ± DP	CV (%)	Média ± DP	CV (%)
Teor no Colmo	(g Kg ⁻¹)	8 ± 1.7	21	7 ± 0.9	13	7 ± 0.6	9
Teor Total'		29 ± 3	10	27 ± 2.9	11	25 ± 2.8	11
Exportação	(Kg ha ⁻¹)	335 ± 78	23	209 ± 58	28	135 ± 35	26
Extração		417 ± 72	17	251 ± 55	22	172 ± 39	23

Para a validação dos modelos de regressão entre os índices de vegetação e os teores de fósforo na atual pesquisa os valores dos coeficientes de determinação apresentados indicaram que os modelos apresentaram fracas correlações, não sendo satisfatórios para a avaliação da variabilidade de fósforo (tabela 20).

Tabela 20 – Valores dos coeficientes de determinação para os modelos de regressão na predição dos teores de fósforo na cultura da cana-de-açúcar.

Fósforo				
Coeficiente de Determinação (R ²)				
Índices de Vegetação	Teor Total	Teor do colmo	Exportação	Extração
	(g Kg ⁻¹)		(Kg ha ⁻¹)	
GRVI	0.20	0.10	0.23	0.30
NDVI	0.19	0.09	0.23	0.29
NDRE	0.21	0.11	0.20	0.26
GNDVI	0.20	0.09	0.21	0.28
SAVI	0.18	0.07	0.27	0.32
RVI	0.23	0.10	0.21	0.28

Para os modelos de regressão dos teores de potássio e os índices de vegetação na cultura da cana-de-açúcar para a determinação dos teores de totais e dos teores nos colmos os coeficientes apresentaram valores baixos, indicando que não há significância. Por outro lado, quando adicionou a biomassa a e massa de colmos para trabalhar com exportação e extração do nutriente os valores dos modelos de regressão foram significativos (Tabela 21), pois os valores dos coeficientes de determinação foram superiores a 0.7, indicando que os modelos podem ser utilizados na predição da exportação e extração de potássio. Todos os índices apresentaram valores superiores a 0.7, com isso todos os índices podem ser utilizados para avaliação da exportação e extração de potássio.

Tabela 21 – Valores dos coeficientes de determinação dos modelos de regressão dos índices de vegetação na avaliação da variabilidade do nutriente para a cultura.

Índices de Vegetação	Potássio			
	Coeficiente de Determinação (R^2)			
	Teor Total	Teor do colmo	Exportação	Extração
	(g Kg ⁻¹)		(Kg ha ⁻¹)	
GRVI	0.30	0.07	0.77	0.76
NDVI	0.30	0.07	0.76	0.74
NDRE	0.28	0.08	0.73	0.71
GNDVI	0.28	0.08	0.73	0.72
SAVI	0.32	0.05	0.77	0.77
RVI	0.29	0.08	0.75	0.75

Na figura 15 são apresentados os gráficos referentes aos modelos de regressão na avaliação da variabilidade da exportação de potássio, e na figura 16 para a extração. Os gráficos apresentados foram os quais apresentaram valores de coeficientes de determinação maiores que 0.7, sendo valores considerados satisfatórios perante aos estudos dos teores de nutrientes nas plantas, pois trabalhos da literatura é possível encontrar valores de R^2 em torno de 0.5 a 0.8.




Figura 15 – Modelos de regressão referente aos índices de vegetação a os valores de exportação do nutriente potássio com os respectivos valores de coeficientes de determinação.




Figura 16 – Modelos de regressão referente aos índices de vegetação a os valores de extração do nutriente potássio com os respectivos valores de coeficientes de determinação.

4.7) Avaliação da textura do solo nas diferentes zonas de manejo

Por meio das coletas de solo foram avaliadas a textura dos solos das diferentes zonas de manejo, posteriormente as texturas foram classificadas de acordo com a Embrapa (2018). Para a zona de manejo de alto potencial produtivo os teores de argila são maiores em relação as demais zonas de manejo, com isso a classificação é de textura média. Em relação a zona de médio e baixo potencial as quantidades de argila são 3% menores em relação a zona de alto potencial, consequentemente os teores de areia são maiores, com isso a classificação de ambas é de textura arenosa.

Tabela 22 – Classificação das análises físicas do solo quanto as texturas das diferentes zonas de manejo.

Zona de Manejo	Prof. (m)	Argila	Silte (g kg)	Areia	Classe de Textura
Alto Potencial Produtivo	0.0 - 0.2	180	33	786	Textura Média
	0.2 - 0.4	156	46	798	Textura Média
Médio Potencial Produtivo	0.0 - 0.2	128	45	826	Textura Arenosa
	0.2 - 0.4	128	38	834	Textura Arenosa
Baixo Potencial Produtivo	0.0 - 0.2	125	21	854	Textura Arenosa
	0.2 - 0.4	126	44	830	Textura Arenosa

5) Discussão

O objetivo do trabalho foi avaliar a variabilidade espacial e temporal da produtividade da cana-de-açúcar, a fim de identificar as diferentes zonas de manejo por meio do uso de tecnologias, tais como o mapa de produtividade e imagens de sensoriamento remoto provenientes de sensores multiespectrais, além disso avaliar a fertilidade dos solos, principalmente os teores de fósforo e potássio, textura do solo das diferentes zonas de manejo e os teores de nutrientes nos tecidos vegetais.

Ao utilizar as ferramentas de sensoriamento remoto na identificação da variabilidade espacial e temporal da produtividade da cana-de-açúcar os índices de vegetação mostraram eficiência na avaliação, pois na safra 2018/2019 as imagens de sensoriamento remoto mostraram que os valores superiores dos índices de vegetação indicaram regiões ou locais da lavoura de produtividades superiores, e para isso foi avaliada a produtividade estimada para cada zona de zona de manejo indicada pelos índices de vegetação. No caso os valores superiores dos índices de vegetação GRVI, NDVI, NDRE, GNDVI, SAVI e RVI indicaram uma região da lavoura com uma produtividade estimada de 114 Mg ha⁻¹. Logo, ao avaliar os valores intermediários dos índices de vegetação foi observado uma produtividade de 107 Mg ha⁻¹, produtividade a qual permitiu classificar a zona de manejo como de médio potencial produtivo, e consequentemente os valores inferiores dos índices de vegetação mostraram uma região de menor produtividade ou de baixo potencial produtivo, a qual apresentou uma produtividade estimada de 87 Mg ha⁻¹. Com a obtenção dos resultados na avaliação da cana planta foi possível observar a variabilidade da produtividade, e que na respectiva área existem fatores que promovem a variabilidade dentro da lavoura. Diversos autores, tais como Candiago et al., (2015), Marino et al., (2018) e Martínez-Casasnovas et al.,

(2018) com o uso de ferramentas de sensoriamento remoto classificaram as zonas de manejo nas lavouras como de alto, médio e baixo potencial por meio das diferenças no espectro das refletâncias.

Quanto a avaliação da variabilidade espacial e temporal da cultura ao longo do ciclo da cultura na safra 2019/2020, foi observado que os índices de vegetação apresentaram valores superiores na região de alto potencial, isso é indício de uma produção superior de biomassa da cultura, ou seja, um melhor desenvolvimento vegetativo da cultura. Para os valores intermediários dos índices de vegetação, a produção de biomassa ou desenvolvimento da cultura foi classificado como médio para a situação, e por consequência nos locais da lavoura que a produção de biomassa foi inferior, a refletância foi menor, interferindo nos valores dos índices de vegetação, que porventura foram valores inferiores. O comportamento espectral ocorreu ao longo de todo o ciclo, sendo constatado de forma mais precisa na colheita, em que a produtividade real nas áreas de valores superiores dos índices de vegetação foi de 103 Mg ha⁻¹, para os valores intermediários dos índices de vegetação a produtividade real foi de 82 Mg ha⁻¹, e por fim nas regiões que os índices foram inferiores a produtividade real foi de 76 Mg ha⁻¹.

O fato de os índices de vegetação serem precisos no estudo da variabilidade de cultivos de culturas ou satisfatórios na determinação de parâmetros agrônômicos, é pelo fato que os índices de vegetação utilizam bandas espectrais das regiões do visível, e no caso as bandas espectrais da região do visível estão relacionadas com a presença de pigmentos fotossintéticos, como a clorofila, pois quanto maior a presença de clorofila na planta mais acentuada será a refletância do dossel na região do Green, por consequência a absorção será reduzida na mesma. Por outro lado, quando a planta tem produção de clorofila acentuada a absorção nas regiões do Red e Blue do espectro são mais intensificadas, logo a refletância é reduzida (Gitelson et al., 2002; Hatfield et al., 2008). Quanto aos índices de vegetação NDVI, NDRE, GNDVI, SAVI e RVI, os quais também apresentaram resultados satisfatórios utilizam a banda do NIR, em que é uma região do espectro a qual é influenciada pelas estruturas internas da folha, devido à ausência de absorção pelos pigmentos e a dispersão da energia eletromagnética no mesófilo das folhas, apresentando alta relação com o conteúdo de clorofila e apresentando alta refletância (Molin, 2015; Diacono et al., 2013; Ashapure et al., 2019). Logo, a região do NIR representa de forma precisa a atividade fotossintética, ou seja, quando o processo fotossintético for mais acentuado, os valores de pixels na região do NIR são superiores

em comparação aos valores de pixels provenientes de um processo fotossintético reduzido. Portanto, a planta ao apresentar um processo fotossintético mais eficiente a produção de fotoassimilados e de biomassa será mais acentuada, ou seja, o desenvolvimento da planta é superior, resultando em maior translocação de sacarose para os colmos, e por fim apresentando melhores produtividades (Rodrigues, 2018). No caso do atual trabalho em que a maior produção de biomassa apresentou valores superiores dos índices de vegetação, as regiões de média produção de biomassa apresentaram valores intermediários para os índices de vegetação, e consequentemente as regiões de baixa produção de biomassa as refletâncias foram menores explica que o processo fotossintético ao ser mais eficiente as refletâncias serão superiores concordando com alguns autores que utilizaram das ferramentas de sensoriamento remoto na definição de diferentes zonas de manejo (Yeom et al., 2019; Di Gennaro et al., 2019; Bendig et al., 2015).

Marino et al., (2018) que observaram o mesmo comportamento para a cultura do trigo, e concluíram que os índices de vegetação foram eficientes na avaliação da variabilidade ao longo da estação de cultivo. Outra questão a ser levantada é o comportamento dos índices de vegetação de acordo com o ciclo da cultura, em que nas imagens de 133 a 254 dias após a colheita, ou de outubro de 2019 a fevereiro de 2020 os índices de vegetação apresentaram um comportamento em que os valores aumentaram, isso indica que a cultura da cana-de-açúcar estava em desenvolvimento vegetativo acentuado, ou seja, acumulando biomassa, pois o período é favorável, devido a precipitação, período de alta intensidade luminosa e altas temperaturas (Rodrigues, 2018). Por outro lado, partir de março em diante os valores dos índices de vegetação tendem a diminuir e estabilizar, pelo fato da cultura estar entrando em processo de maturação, em que o aparato fotossintético diminui a eficiência, pelo fato de as temperaturas diminuírem, as chuvas reduzirem e os dias ficarem mais curtos, e no caso ocorre redução na taxa de crescimento da cultura e aumento do teor de sacarose.

Com a obtenção do mapa de produtividade foi possível contabilizar as produtividades reais obtidas na área de cana-de-açúcar, para posteriormente utilizar o mapa de produtividade a fim de delimitar as respectivas zonas de manejo. No caso, na delimitação das zonas de manejo foram utilizadas as imagens adquiridas dos índices de vegetação ao longo da safra e o mapa de produtividade. Posteriormente foi utilizada a técnica Fuzzy k-means para a delimitação das zonas de manejo, por de dois índices o FPI (Índice de Performance Fuzzy) e o MPE (Índice de Entropia de Partição Modificada), os

quais apresentam valores de 0 a 1, em que valores próximos a 0, indicam regiões de classes diferentes, ou seja, regiões que apresentam diferenças entre elas. Por outro lado, valores próximos a 1 são identificadas regiões semelhantes.

O índice de vegetação RVI, foi o qual apresentou os menores valores de FPI e MPE, em torno de 0.051 e 0.066, indicando ser o índice mais preciso na determinação das zonas de manejo com a combinação de 3 imagens, a imagem da colheita da safra 2018/2019, imagem da colheita 2019/2020 e com a imagem de 225 após a colheita de 2018/2019, e mais o mapa de produtividade. Além disso, os outros índices mostraram resultados satisfatórios, pois os valores dos índices FPI e MPE foram próximos de 0. Para todas as combinações mais precisas com cada índice de vegetação as classes determinadas foram 3 classes ou zonas de manejo. O resultado encontrado é pertinente ao resultado encontrado por outros autores como Song et al., (2009) e Martínez-Casasnovas et al., (2018) que ao utilizarem índices de vegetação na definição de zonas de manejo encontraram resultados semelhantes e próximos de 0. Com a definição das zonas de manejo pelo método de fuzzy k-means foi observado que os índices de vegetação por meio das diferenças do espectro permitiram identificar de forma precisa as zonas de manejo, já que os pontos de coleta de solo e planta identificados a princípio pelo sensoriamento remoto foram estabelecidos dentro das zonas de manejo. Além disso, autores como Canata et al., (2021) concluíram que os índices de vegetação são ferramentas exatas para a definição de zonas de manejo, pois os índices NDVI, NDRE e GNDVI mostraram valores de R^2 significativos, em torno de 0.58, 0.60 e 0.57 ao correlacionar com o mapa de produtividade. Com a validação dos mapas dos índices de vegetação como ferramentas precisas de agricultura de precisão na identificação da variabilidade espacial e temporal da produtividade da cana-de-açúcar é possível afirmar que os mapas dos índices são precisos na delimitação de zonas de manejo, por meio disso foi utilizado o mapa de produtividade e o mapa do índice de vegetação NDVI, o qual foi mais preciso na correlação com a produtividade para a identificação das zonas de manejo, as quais foram classificadas como zona de manejo de alto potencial produtivo, zona de manejo de médio potencial produtivo e zona de manejo de baixo potencial produtivo.

Com os resultados obtidos das análises de solo por meio do uso do sensoriamento remoto foram identificados os teores de fósforo e potássio para as diferentes zonas de manejo. Os teores de fósforo no solo na safra 2018/2019 foram considerados adequados, porém o potássio foi classificado como baixo para ambas as zonas de manejo. Para a safra

2019/2020 o teor de fósforo estava adequado para as zonas de médio e baixo potencial, porém para a zona de alto potencial os teores foram classificados como baixo, fato que pode ser explicado pela extração em maior quantidade do nutriente, devido a maior produtividade. No caso do potássio, os teores foram classificados como médio para a camada 0.0 – 0.2 m em ambas as zonas de manejo, e baixo nas camadas 0.2 – 0.4 m. Com os resultados das amostras de solo foi possível identificar a situação de fertilidade de solo para cada zona de manejo, e por fim ao saber o potencial de cada zona de manejo é possível otimizar a aplicação de insumos e não utilizar da aplicação a taxa fixa, pois no caso a aplicação do fertilizante em dose única para todas as zonas de manejo haveria prejuízos, e consequentemente um investimento de doses variáveis de fertilizantes acarretariam incremento na produtividade.

Para os teores de fósforo e potássio nos tecidos das plantas na safra 2018/2019 foram observados que as zonas de alto, médio e baixo potencial produtivo apresentaram teores totais e teores no colmo similares para fósforo e para potássio, ou seja, não houve variabilidade para os teores. Quanto a exportação e extração as zonas de alto e médio potencial apresentaram valores superiores pelo fato de apresentarem produtividade superior quando comparada a zona de baixo potencial produtivo. Para as produtividades obtidas em cada zona de manejo foram exigidos em torno de 0.71, 0.78 e 0.38 Kg de P por tonelada de colmo para a zona de alto, médio e baixo potencial produtivo, indicando que as exigências estão de acordo com o necessário (Otto et al., 2019). Quanto a validação dos índices de vegetação para determinação dos teores de nutrientes, exportação e extração os modelos de regressão não foram significativos, devido as zonas de manejo não apresentarem variabilidade nos teores dos nutrientes, e no caso segundo Furlanetto et al., (2021) para obter resultados significativos dos índices de vegetação na predição dos teores de nutrientes é preciso ter teores diferentes no solo e na planta.

Para a safra 2019/2020 os teores totais e teores no colmo de fósforo e potássio foram similares para as três zonas de manejo, fato que explica o porquê de os índices de vegetação não serem significativos na predição dos teores, pois de acordo com Osborne et al., (2002) para a obtenção de correlações significativas é necessário a alta variação entre os teores nos diferentes valores do espectro. Porém ao adicionar a massa de colmos e a biomassa para identificar a variabilidade das extrações e exportações dos nutrientes foram obtidos resultados significativos para a exportação e extração de K, em que os valores de coeficientes de determinação foram superiores a 0.7, indicando forte

correlação, ou seja, por meio dos índices de vegetação foi possível identificar a variabilidade da exportação e extração de potássio na cultura da cana-de-açúcar, tal fato foi observado por Mahajan et al., (2014) e Lu et al., (2021) que na obtenção de valores significativos para identificação da variabilidade de potássio adicionaram a biomassa e concluíram que ao adicionar a biomassa é avaliada as folhas fotossinteticamente ativas, as quais apresentam abertura e fechamento dos estômatos e teores de água na planta devido ao nutriente potássio.

Em relação a textura do solo, a zona de alto potencial produtivo apresentou teores maiores de argila no solo, fato que proporcionou incremento na produtividade em comparação as outras zonas de manejo, já que a presença maior de argila permite uma retenção maior da água no sistema solo e teores maior de argila as perdas de potássio são menos intensificadas.

6) Conclusão

Por meio do uso do sensoriamento remoto foi possível identificar a variabilidade espacial e temporal da produtividade da cana-de-açúcar, ou seja, a combinação entre as imagens de sensoriamento remoto dos índices de vegetação e do mapa de produtividade permitiram identificar as diferentes zonas de manejo.

Os índices de vegetação mostraram satisfatórios para serem utilizados como ferramentas para adoção de zonas de manejo, já que os valores de FPI e MPE foram próximos de 0, indicando que as diferentes zonas de manejo apresentam acentuada diferença entre elas, sendo assim permitindo um manejo específico para cada uma delas. No caso, o índice de vegetação RVI foi o mais preciso na definição das zonas de manejo, seguido pelo índice de vegetação NDVI, NDRE, SAVI, GNDVI e GRVI. Além disso, os índices de vegetação mostraram que os valores superiores indicam regiões de potenciais produtivos superiores, valores intermediários indicam regiões de médio potencial produtivo e por fim valores inferiores dos índices indicaram regiões de baixo potencial produtivo.

Com a determinação das zonas de manejo foi avaliado os atributos químicos do solo e das plantas, em que cada zona de manejo obteve uma determinada classificação quanto a fertilidade do solo e quanto os teores de nutrientes nas plantas, sendo assim cada zona de manejo permite ser manejada de forma diferente quanto a aplicação de fertilizantes potássicos e fosfatados, e com isso obter resultados melhores em

produtividade, otimização de recursos e gestão da variabilidade da lavoura. Além disso, a utilização do sensoriamento remoto permitiu identificar a diferença de textura entre as zonas de manejo, a fim de programar as práticas culturais de forma mais eficiente.

7) Referências Bibliográficas

Ashapure, A.; Jung, J.; Chang, A.; Oh, S.; Maeda, M. & Landivar, J. A Comparative Study of RGB and Multispectral Sensor-Based Canopy Cover Modeling Using Multi-Temporal UAS Data. *Remote Sensing*, 2019, 11, 2757; doi:10.3390/rs11232757.

Amaral, L.R. & Molin, J. P. Sensor óptico no auxílio a recomendação de adubação nitrogenada em cana-de-açúcar. *Pesquisa Agropecuária Brasileira*, Brasília, v. 16. p. 1633-1642, 2011. <https://doi.org/10.1590/S0100-204X2011001200008>.

Bang, T. C.; Husted, S.; Laursen, K. H.; Persson, D. P.; Schjoerring, J. K. The molecular–physiological functions of mineral macronutrients and their consequences for deficiency symptoms in plants. *New Phytologist*, v. 229, n. 5, p. 2446 – 2469, 2020. <https://doi.org/10.1111/nph.17074>

Barnes, E.M.; Clarke, T.R.; Richards, S.E.; Colaizzi, P.D.; Haberland, J.; Kostrzewski, M.; Waller, P.; Choi, C.; Riley, E.; Thompson, T.; et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In *Proceedings of the Fifth International Conference on Precision Agriculture*, Bloomington, MN, USA, 16–19 July 2000; Volume 1619.

Barbedo, J. G. A. A Review on the Use of Unmanned Aerial Vehicles and Imaging Sensors for Monitoring and Assessing Plant Stresses. *Drones* 2019, 3, 40; doi:10.3390/drones3020040

Bendig, J.; Yu, K.; Aasen, H.; Bolten, A.; Bennertz, S.; Broscheit, J.; Gnyp, M.L.; Bareth, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *Int. J. Appl. Earth Obs. Geoinf.* 2015, 39, 79–87. <http://dx.doi.org/10.1016/j.jag.2015.02.012>

Bezdek, J.C.; Ehrlich, R.; Full, W. FCM: The fuzzy c-means clustering algorithm. *Comput. Geosci.* 1984, 10, 191–203. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7).

BRUCE, R. W.; RAJCAN, I. & SULIK, J. Plot extraction from aerial imagery: A precision agricultura approach. *The Plant Phenome Journal*. 2020, 3, 1 – 6. DOI: 10.1002/ppj2.20000. DOI: 10.1002/ppj2.20000

Canata, T.F.; Wei, M.C.F.; Maldaner, L.F.; Molin, J.P. Sugarcane Yield Mapping Using High-Resolution Imagery Data and Machine Learning Technique. *Remote Sens.* 2021, 13, 232. <https://doi.org/10.3390/rs1302023>

Di Gennaro, S. F.; Dainelli, R.; Palliotti, A.; Toscano, P. & Matese, A. Sentinel-2 Validation for Spatial Variability Assessment in Overhead Trellis System Viticulture

Versus UAV and Agronomic Data. *Remote Sensing*. 2019, 11, 2573; doi:10.3390/rs11212573.

Companhia Nacional de Abastecimento (CONAB, 2022). Acompanhamento de safra brasileira: cana-de-açúcar, 3º levantamento, dezembro/2022. CONAB, Brasília.

Diacono, M., Rubino, P., Montemurro, F., 2013. Precision nitrogen management of wheat. A review. *Agron. Sustain. Dev.* 33, 219–241. <https://doi.org/10.1007/s13593-012-0111-z>

Gitelson, A. A.; Gritz, Y.; Merzlyak, M.N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *J. Plant Physiol.* **2003**, 160, 271–282. [https://doi.org/10.1016/S0176-1617\(11\)81633-0](https://doi.org/10.1016/S0176-1617(11)81633-0)

Gitelson, A.A., Y.J. Kaufman, R. Stark, and D. Rundquist. 2002b. Novel algorithms for remote estimation of vegetation fraction. *Remote Sens. Environ.* 80:76–87.

Guo, X.Y., Zhu, X.C., Li, C., Wei, Y., Yu, X.Y., Zhao, G.X. and Sun, H.X. (2017) Hyperspectral Inversion of Potassium Content in Apple Leaves Based on Vegetation Index. *Agricultural Sciences*, 8, 825-836. <https://doi.org/10.4236/as.2017.88061>

Hatfield, J. L.; Gitelson, Anatoly A.; Schepers, James S.; and Walthall, C. L., "Application of Spectral Remote Sensing for Agronomic Decisions" (2008). *Agronomy Journal* (2008) 100: S-117-S-131. DOI: 10.2134/agronj2006.0370c

Humbert, R.P. (1968) Nutrition of sugar cane. In: *The Growing of Sugar Cane*, Elsevier, Amsterdam, 133

Lima-Cueto, F.; Blanco – Sepúlveda, R.; Gómez – Moreno & Galacho - Jiménez, F. B. Using Vegetation Indices and a UAV Imaging Platform to Quantify the Density of Vegetation Ground Cover in Olive Groves (*Olea Europaea* L.) in Southern Spain. *Remote Sens.* 2019, 11, 2564; doi:10.3390/rs11212564.

Loozen, Y.; Karssenbergh, D.; Jong, S. M.; Wang, S.; Dijk, J.; Wassen, M. & Rebel, K. Exploring the use of vegetation indices to sense canopy nitrogen to phosphorous ratio in grasses. *Int J Appl Earth Obs Geoinformation*. V. 75, p. 1 – 14, 2019. <https://doi.org/10.1016/j.jag.2018.08.012>

Mahajan, G.R.; Sahoo, R. N.; Pandey, R. N.; Gupta, V. K. & Kumar, D. Usando técnicas de sensoriamento remoto hiperespectral para monitorar nitrogênio, fósforo, enxofre e potássio em trigo (*Triticum aestivum* L.). *Precision Agriculture*, v. 15 (5), p. 499-522, 2014. DOI 10.1007/s11119-014-9348-7

Marschner H. *Nutrição mineral de plantas superiores*. 2 ed. London: Academic Press, 1995. 889p.

Molin, J. P.; Mascarín, L. S.; Vieira junior, P. A. Assess site-specific fertilizer and corn plant population (Avaliação de intervenções em unidades de aplicação localizada de fertilizantes e de populações de milho). *Engenharia Agrícola*, Jaboticabal, v.26, p.528–536, 2006. <http://dx.doi.org/10.1590/S0100-69162006000200022>

Molin, J.P.; Frasson, F.R.; Amaral, L.R.; Povh, F.P.; Salvi, J.V. Capability of an optical sensor in verifying the sugarcane response to nitrogen rates. (In Portuguese, with English abstract.) *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campinas Grande, v. 14, n. 12, p.1345-1349, 2010.

Orlando filho, J. (Coord.). *Nutrição e adubação da cana-de-açúcar no Brasil*. Piracicaba: IAA/Planalsucar, 1983. 369 p. (Planalsucar).

Osborne, S. L.; Schepers, J. S.; Francis, D. D. & Schlemmer, M. R. Detection of Phosphorus and Nitrogen Deficiencies in Corn Using Spectral Radiance Measurements. *Remote Sensing*, v. 94, n. 6, p. 1215 – 1221, 2002. <https://doi.org/10.2134/agronj2002.1215>

Otto, R.; Altarugio, L. M.; Sanchez, G. M. Atualizações sobre exigências nutricionais da cana-de-açúcar para fins de manejo da adubação. *Informações Agrônomicas NPCT*, Piracicaba, n.3, p. 1 – 8, 2019.

Park, D.M.; Cisar, J.L.; Williams, K.E.; McDermitt, D.K.; Miller, W.P.; Fidanza, M.A. Using spectral reflectance to document water stress in bermudagrass grown on water repellent Sandy soils. *Hydrol. Proc.* **2007**, *21*, 2385-2389.

Pereira, G.; Valente, D.; Queiroz, D.; Coelho, A.; Costa, M.; Grift, T. Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. *Agronomy* **2022**, *12*, 1350. <https://doi.org/10.3390/agronomy12061350>

Pimstein, A.; Karnieli, A.; Bansal, S. K. & Bonfil, D. J. Explorando tecnologias de sensoriamento remoto para monitoramento de potássio e fósforo de trigo usando espectroscopia de campo. *Field Crops Research*, v. *121* (1), p. 125–135, 2011. doi:10.1016/j.fcr.2010.12.001

Portz, G.; Molin, J. P.; Jasper, J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields. *Precision Agriculture*, v. 13, p.33-44, 2012. DOI 10.1007/s11119-011-9243-4

Prado, R. M. *Nutrição de plantas*. São Paulo: UNESP, 2008. 407 p.

Malavolta, E. *Manual de nutrição mineral de plantas*. São Paulo: Agronômica Ceres, 2006. 638p.

RAIJ, B. VAN; ANDRADE, J.C.; CANTARELLA, H. & QUAGGIO, J.A. *Análise química para avaliação da fertilidade de solos tropicais*. Campinas, Instituto Agronômico, 2001. 284p.

Raij, B. Van; *Fertilidade do Solo e Manejo de Nutrientes*. 2. Piracicaba: International Plant Nutrition Institute, 2017. 420 p.

Rodrigues, J. D. *Fisiologia da produção de Cana-de-açúcar*. São Paulo: ANDREI, 2018. 178 p.

Rosseto, R.; DIAS., F. L. F.; Vitti, A. C.; Cantarella, H.; Landell, M. G. A. Manejo Conservacionista e reciclagem de nutrientes na cana-de-açúcar tendo em vista a colheita mecânica. *Informações Agronômicas*, Campinas, v. 1, p. 8 – 13, 2008.

Rouse, J.W., Jr.; Haas, R.H.; Schell, J.A.; Deering, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In NASA Goddard Space Flight Center 3d ERTS-1 Symposium; NASA: Washington, DC, USA, 1974; Volume 1, pp. 309–317.

Sanches, G.; Otto, R.; Adamchuck, V.; Magalhães., P. S. G. Spatial Variability of soil attributes by an eletromagnetic induction sensor: A framework of multiple Fields assessment under Brazilian soils. *Science Direct*, 216, p. 229 – 240, 2022. <https://doi.org/10.1016/j.biosystemseng.2022.02.017>

Severtson, D.; Callow, N.; Flower, K.; Nehuhaus, A.; Olejnik, M. & Nansen, C. Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola. *Precision Agriculture*, v. 17, p. 659 – 677, 2016. DOI 10.1007/s11119-016-9442-0

Schwalbert, R. A.; Amado, T. J. C. ; Gebert, F. H. ; Santi, A. L. ; Tabaldi, F. . Zonas de manejo: atributos de solo e planta visando a sua delimitação e aplicações na agricultura de precisão. *Revista Plantio Direto*, v. 13, p. 21-32, 2014.

Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 1979, 8, 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

Yeom, J.; Jung, J.; Chang, A.; Ashapure, A.; Maeda, M.; Maeda, A. & Landivar, J. Comparison of Vegetation Indices Derived from UAV Data for Differentiation of Tillage Effects in Agriculture. *Remote Sensing*, 2019, 11, 1548; doi:10.3390/rs11131548.

Zambrosi, F. C. B.; Ribeiros, R. V.; Marchiori, P. E. R.; Cantarella, H. & Landell, M. G. A. Sugarcane performance under phosphorous deficiency: physiological responses and genotypic variation. *Plant Soil*, 386: 273-283, 2015. DOI 10.1007/s11104-014-2252-0

Zambrosi, F. C. B.; Ribeiros, R. V.; Machado, E. C. & Garcia, J. C. Phosphorous deficiency impairs shoot regrowth of sugarcane varieties. *Expl Agric*, v. 53, p. 1 – 11, 2016.

Zhang, C. and Kovacs, J. M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, v.13, p.693-712, 2012. <http://dx.doi.org/10.1007/s11119-012-9274-5>

