

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Instituto de Geociências
Programa de Pós-Graduação em Geografia

Gustavo Ferreira de Souza

**AGRICULTURA DE PRECISÃO POR SENSORIAEMNTO REMOTO: ESTUDO
APLICADO NA FERTIRRIGAÇÃO DE CANA-DE-AÇUCAR**

Belo Horizonte

2022

Gustavo Ferreira de Souza

**AGRICULTURA DE PRECISÃO POR SENSORIAEMNT0 REMOTO: ESTUDO
APLICADO NA FERTIRRIGAÇÃO DE CANA-DE-AÇUCAR**

Tese apresentada ao Programa de Pós-Graduação em Geografia da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Geografia.

Área de concentração: Análise Ambiental

Orientadora: Profa. Dra. Ana Clara Mourão
Moura

Co-Orientador: Professor Carlos Fernando
Ferreira Lobo

Belo Horizonte

2022

S729a Souza, Gustavo Ferreira de.
2022 Agricultura de precisão por sensoriamento remoto [manuscrito] : estudo aplicado na fertirrigação de cana-de-açúcar / Gustavo Ferreira de Souza. – 2022.
110 f., enc.: il. (principalmente color.)
Orientadora: Ana Clara Mourão Moura.
Coorientador: Carlos Fernando Ferreira Lobo.
Tese (doutorado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2022.
Área de concentração: Análise Ambiental.
Bibliografia: f. 94-110.
1. Sensoriamento remoto – Teses. 2. Agricultura de precisão – Teses. 3. Fertirrigação – Teses. 4. Cana-de-açúcar – Teses. I. Moura, Ana Clara Mourão. II. Lobo, Carlos. III. Universidade Federal de Minas Gerais. Instituto de Geociências. IV. Título.

CDU: 528.8



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
COLEGIADO DO CURSO DE PÓS-GRADUAÇÃO EM GEOGRAFIA

FOLHA DE APROVAÇÃO

AGRICULTURA DE PRECISÃO POR SISTEMAS ORBITAIS DE SATÉLITES: APLICAÇÕES NA FERTIRRIGAÇÃO

GUSTAVO FERREIRA DE SOUZA

Tese de Doutorado defendida e aprovada, no dia 21 julho de 2022, pela Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Geografia da Universidade Federal de Minas Gerais constituída pelos seguintes professores:

Gabriel Pereira

UFSJ

Alan Nunes Araújo

UFPA

Cézar Henrique Barra Rocha

UFJF

Úrsula Ruchkys de Azevedo

IGC/UFMG

Carlos Fernando Ferreira Lobo

IGC/UFMG

Ana Clara Mourão Moura - Orientadora

EA/UFMG

Belo Horizonte, 22 de julho de 2022.



Documento assinado eletronicamente por **Ana Clara Mourão Moura, Professora do Magistério Superior**, em 21/07/2022, às 12:57, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Gabriel Pereira, Usuário Externo**, em 21/07/2022, às 14:57, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alan Nunes Araújo, Usuário Externo**, em 21/07/2022, às 15:46, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ursula Ruchkys de Azevedo, Chefe de departamento**, em 22/07/2022, às 07:50, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **César Henrique Barra Rocha, Usuário Externo**, em 09/08/2022, às 14:01, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Carlos Fernando Ferreira Lobo, Professor do Magistério Superior**, em 12/08/2022, às 08:30, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1594416** e o código CRC **DDB29B8B**.

AGRADECIMENTOS

A minha família, minha mãe Sueli Helma da Silva Souza, meu pai Antônio Ferreira de Souza e meu irmão Gabriel Ferreira de Souza que acreditaram e plantaram a semente que me direcionou para chegar até o desenvolvimento desse trabalho.

Aos professores que contribuíram direta e indiretamente para meu aprendizado e crescimento profissional na UFMG, em especial a Professora Dra. Ana Clara Mourão Moura e Professor e Professor Dr. Carlos Fernando Ferreira Lobo que confiaram no trabalho e me inspiraram a voltar para os trilhos.

A sociedade brasileira que contribui para que o sistema de ensino público e gratuito seja o melhor para toda a comunidade. A CAPES por proporcionar recursos fundamentais para a execução da pesquisa.

Ao IGC, que sentirei saudades de percorrer o prédio e tomar café todas as tardes na cantina pós trabalho no laboratório.

Na graduação, o meu orientador de TCC que me despertou a paixão pela pesquisa, Professor Dr. Antônio Conceição Paranhos Filho (Toni) (UFMS). Ao Professor Dr. William Tsé Horng Liu (UCDB), que me proporcionou o primeiro contato com o sensoriamento remoto de alto nível ao me colocar para revisar capítulos do livro que ele viria a publicar mais tarde. Ao Professor Msc. Ayr Trevisanelli Salles (UCDB), por me proporcionar o primeiro estágio com geoprocessamento. Pela paixão com a Geografia, ao Professor Msc. Arnaldo Rodrigues Menecozi (UCDB).

No mestrado, mesmo não sendo a minha orientadora, mas foi quem me despertou para o doutorado a Professora Dr. Marcilene Ferreira Dantas (UFSCar).

Aos amigos Eng. Renan Florentino Santos e Eng. Carlos Rodrigues da Cunhas Junior, pela parceria pessoal e profissional.

A empresa SJC Bioenergia que foi solícita e forneceu todos os dados.

Por fim, todos aqueles que estão do nosso lado nos ajudando e muitas vezes não percebemos, gratidão eterna.

RESUMO

Este trabalho oferece uma contribuição metodológica aplicada de monitoramento, controle e avaliação tecnológica por sensoriamento remoto no manejo agrícola de áreas irrigadas com vinhaça (Fertirrigação) na produção de cana-de-açúcar, para prover produtividade com sustentabilidade. O desafio de produção em grandes áreas e a capacidade geográfica de mensurações limitada em campo, a disponibilidade de dados por satélites foi aplicada ao estudo, com vistas à discussão sobre monitoramento em um processo de produção agrícola. O processo de fertirrigação foi o objeto escolhido devido ter um alto valor agregado, com execução de três processos em um: 1- Transforma um resíduo em insumo, 2 - irriga a cana no período mais seco 3 – fertiliza o solo. O local de produção ocupa grande extensão geográfica (20 mil hectares), distribuída espacialmente em fazendas próximas e interligadas, porém de difícil controle e monitoramento da qualidade do processo. O estudo objetivou analisar e elaborar um método com técnicas de sensoriamento remoto (SR), classificação espectral e orientada ao objeto, identificar correlação da produtividade com índices espectrais para monitoramento da fertirrigação; com diferentes sensores orbital remoto. Os dados dos satélites Sentinel 1 e 2, foram a base para avaliar o modelo de mapeamento e o impacto da variação na fertirrigação correlacionado com Sentinel 2 dados de produtividade das áreas. Na avaliação estatística, correlação de Person, houve correlação nas imagens testadas (Sentinel 2, Pearson 0.4 e Anova 0.7) com índices de vegetação extraídos para os de 2017 a 2019. Para os anos de 2019 a 2021, o teste, usou os métodos para avaliar somente o mês de abril (Pico de crescimento da cana) teve correlação (Pearson 0,98) e regressão múltipla (Para variáveis NDVI e NDWI $p < 0,02$). Na classificação orientada ao objeto foi definido um modelo baseado no LSMS (*Large Scale Mean Shift*), que separou as áreas fertirrigadas e a qualidade aplicada, baseado em reposta espectral e experiência de campo. Para a classificação, definiu-se os parâmetros para avaliar a qualidade da fertirrigação (raio espacial 5, Intervalo do raio 200 e tamanho mínimo 50). O método representou uma forma de avaliar e mensurar a qualidade da aplicação da vinhaça como formar irrigar e fertilizar ao mesmo tempo. Com a periodicidade dos satélites é de 5 dias de revisita, permite correção em situações identificação de falhas na aplicação de vinhaça. O trabalho apresentou uma ferramenta que gerou um produto aplicado de forma operacional para monitoramento da qualidade na cobertura do lançamento de vinhaça em irrigação por aspersão.

Palavras-chave: Fertirrigação, Irrigação, Sensoriamento remoto, Agricultura, Agricultura de Precisão.

ABSTRACT

This work offers an applied methodological contribution of monitoring, control and technological evaluation by remote sensing in the agricultural management of areas irrigated with vinasse (Fertirrigation) in the production of sugarcane, to provide productivity with sustainability. The challenge of production in large areas and the limited geographic capacity of measurements in the field, the availability of satellite data was applied to the study, with a view to discussing monitoring in an agricultural production process. The fertigation process was the object chosen due to its high added value, with the execution of three processes in one: 1 - It transforms a residue into an input, 2 - irrigates the cane in the driest period 3 - fertilizes the soil. The production site occupies a large geographic area (20 thousand hectares), spatially distributed in nearby and interconnected farms, but difficult to control and monitor the quality of the process. The study aimed to analyze and develop a method with remote sensing (SR) techniques, spectral and object-oriented classification, to identify productivity correlation with spectral indices for monitoring fertirrigation; with different remote orbital sensors. Data from Sentinel 1 and 2 satellites were the basis for evaluating the mapping model and the impact of variation in fertigation correlated with Sentinel area productivity data. In the statistical evaluation, Person correlation, there was a correlation in the tested images (Sentinel 2, Pearson 0.4 and Anova 0.7) with vegetation indices extracted for those from 2017 to 2019. For the years 2019 to 2021, the test used the methods for evaluating only the month of April (sugarcane growth peak) had correlation (Pearson 0.98) and multiple regression (For NDVI and NDWI variables $p < 0.02$). In the object-oriented classification, a model based on the LSMS (Large Scale Mean Shift) was defined, which separated the fertigated areas and the applied quality, based on spectral response and field experience. For classification, parameters were defined to assess the quality of fertigation (spatial radius 5, radius interval 200 and minimum size 50). The method represented a way to evaluate and measure the quality of the application of vinasse as a way to irrigate and fertilize at the same time. With the periodicity of the satellites of 5 days of revisit, it allows correction in situations of identification of failures in the application of vinasse. The work presented a tool that generated a product applied operationally for monitoring the quality in the coverage of vinasse release in sprinkler irrigation.

Keywords: Fertigation, Irrigation, Remote Sensing, Agriculture, Precision Agriculture.

*Tudo é loucura ou sonho no começo.
Nada do que o homem fez no mundo teve início de outra maneira —
mas já tantos sonhos se realizaram que não temos
direito de duvidar de nenhum.”*

Monteiro Lobato

LISTA DE FIGURAS

Figura 1 - Tolete de cana-de-açúcar. Fonte: KOEHLER et al. 2009	22
Figura 2-Representação cartograma da cana-de-açúcar no Brasil por quantidade produzida em toneladas. Fonte: (IBGE, 2019).....	23
Figura 3- Ranking cana-de-açúcar dos Estados do Brasil por quantidade produzida em toneladas. Fonte (IBGE, 2019).....	24
Figura 4 - Média anual de precipitação na região da área de estudo, sul de Goiás. Fonte: (IBGE, 2019).....	25
Figura 5-Fases fenológicas da cana-de-açúcar Fonte: Sobrinho (2019).....	26
Figura 6 - Área de cana planta fertirrigação com vinhaça. Fonte: O autor.	27
Figura 7 - Evolução da safra de <i>cana-de-açúcar</i> . Fonte: CONAB, 2020.....	28
Figura 8 - Ilustração da pulverização da vinhaça do canal (a) ao hidro-roll (b) para o campo (c). Fonte: O Autor.	32
Figura 9. Ciclo da agricultura de precisão em três etapas (MOLIN et al., 2015).	36
Figura 10 - Exemplos de regiões de interesse (ROIs) para coleta de dados espectrais das variedades V2 (RB855536) e (RB855113). Fonte: Fortes e Demattê, 2006.	44
Figura 11. Interpretação e acurácia por classificação usando algoritmos de <i>machine learning</i> . Fonte: SCHAPIRE, R., 2015.....	49
Figura 12 Hiperplano gerado pelo SVM. Fonte: MITRA, P. S. B. U., & Pal, S. K., 2004.	51
Figura 13. Boosting random forest. Fonte: GIBSON, R. et al. 2020	53
Figura 14. Exemplo de funcionamento das redes neurais. Fonte: PIRES DE LIMA, R.; MARFURT, K., 2019..	55
Figura 15. Ciclo da produção e aplicação da vinhaça como sistema de irrigação e fertilizante (Fertirrigação). Fonte: O autor	58
Figura 16 - Fluxograma e etapas do trabalho. Aquisição dos dados, processamento, segmentação e classificação.RF (Random Forest), SVM (Suport Vector Machine). Fonte: o autor.	64
Figura 17. Local da área de estudo com sob a imagem infra vermelho de abril de 2019 com os principais talhões e amarelo.....	66
Figura 18. Caracterização das áreas de fertirrigação: A) foto do canhão aspersor lançando a vinhaça. B, C, D) Fotos de drone exemplificando o formato e a manchas da aplicação. Fonte: o autor.....	66
Figura 19 - Composição colorida das imagens S-2 (a) e S-1 (b) de 2 de agosto e 1 de agosto de 2018, respectivamente. A imagem colorida S-2 corresponde ao composto "Healthy vegetação" (proposto pelo programa aplicativo SNAP) (IR em vermelho, SWIR em verde, azul em azul). A imagem S-1 é representada com a seguinte composição: VV em vermelho, VH em verde e VV-VH em azul. Fonte: o autor.....	68
Figura 20 - Ilustração do problema de fertirrigação que causa estresse nutricional em algumas lavouras de cana-de-açúcar: (a) Imagem do mapa do Google mostrando uma leve diferença de tom; (b) imagem composta S-2 de SAVI de três datas (agosto, setembro e novembro de 2018); (c) Imagem composta colorida S-1 (VV, VH, VV-VH). Fonte: o autor.....	70
Figura 21 - Características da imagem Sentinel 1 e 2. Fonte (DENIZE, JULIEN, et al.).....	71
Figura 22 - Algoritmo para computar estatística e normalizar as bandas da imagem de satélite - Orfeo Toolbox. Fonte: o autor.	73
Figura 23- Comando Resample para reamostragem de pixel igualar resolução espacial entre bandas. Disponíveis no algoritmo vizinhos mais proximo, bilinear e bicubica. Fonte: o autor.	74
Figura 24 - Configuração para segmentação. Fonte: o autor	75
Figura 25 - Campos de processamento do LSMS. Fonte: o autor.	78
Figura 26 - Código para análise em mineração para encontrar melhor combinação para o modelo de segmentação para áreas fertirrigação com <i>cana-de-açúcar</i> . Fonte: o autor.	80
Figura 27-Gráfico de representação da distribuição dos valores do índice de vegetação para mês de abril de 2021 Fonte: o autor.	84
Figura 28. Gráficos representando a regressão múltipla para todas as amostras e correção normal (Normal Q-Q) com a linha vermelha acompanhando a linha central de referência das avaliações residuais complementares. Fonte: ao autor.....	84
Figura 29. Correlação de Pearson (Escala de valores de p) para médias das safras 2018, 2019, 2020, 2021. Significante a 95% ** significativo a 99%. Fonte: o autor.	85
Figura 30. Diferença entre reamostragem vizinho mais próximo (VP) (A) e bilinear (B). Fonte: o autor.	86

Figura 31 - Foto tirada por drone no momento da irrigação com sistema de recolhimento automático com a seta mostrando o sentido da foto (a). Imagem de satélite Sentinel 2A, composição R8 G4 B3 com a indicação do local da irrigação (b). Foto atrás do sistema de fertirrigação com carretel hidro-roll de 350m (c). Fonte: o autor.	87
Figura 32 - Representação dos parâmetros que melhor separou a variabilidade na aplicação de vinhaça no sistema LSMS.	89
Figura 33 - Distribuição da amostragem para classificação orientada a objeto.	90
Figura 34 - Classificação orientada a objeto baseado no modelo gerado no OTB. Variação nível (1); Variação nível (2); Variação nível (3); Variação nível (4); Zona sem fertirrigação (5).	91

LISTA DE TABELAS

Tabela 1-Periodos da safra de cana-de-açúcar no centro sul do Brasil – Fonte: O autor	25
Tabela 2 - Síntese de aplicações de SR em cana-de-açúcar	38
Tabela 3 - Principal composição química da vinhaça. Fonte: Embrapa, 2015.....	59
Tabela 4 - Parâmetros definidos após testes para chegar aos valores mais adequados para cana	79
Tabela 5 - Resultados da correlação de Pearson entre a tonelagem por hectare (TCH), o número de colheita (NH) e os índices SAVI e NDWI.....	81
Tabela 6 - Análise de variância entre talhões visualmente identificados para mostrar problemas de fertirrigação e talhões sem problemas. Os índices SAVI e NDWI foram analisados individualmente para as seis datas diferentes da imagem S-2.....	82
Tabela 7 - Parâmetros de maior detalhamento da variabilidade no manejo de irrigação com vinhaça.	88

LISTA DE ABREVIATURAS

AP	Agricultura de Precisão
CTC	Centro de tecnologia da cana
CBERS	China Brasil Earth Resources Satellite
ERS-1	<i>European Remote Sensing - 1</i>
ESA	<i>European satellite agency</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
EU	<i>Europe union</i>
EUA	Estados Unidos da América
FAO	<i>Food agriculture organization</i>
FPAR	<i>Fraction Photosynthetically active radiation</i>
GNSS	<i>Global navigation satellite system</i>
GPS	<i>Global Navigation Satellite</i>
IAC	Instituto agrônomo de Campinas
IV	Índice de vegetação
LAI	<i>Leaf area index</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSS	<i>Multi spectral systems</i>
NASA	<i>Nation Administration satellite agency</i>
NDVI	<i>Normalized difference vegetation index</i>
NDWI	<i>Normalized difference water index</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
OBIA	<i>Objected-Based orientation</i>
OTB	<i>Orfeo Tool Box</i>
RB	Ridesa
RF	<i>Random Forest</i>
SAR	<i>Synthetic aperture radar</i>
SAVI	<i>Soil adjusted vegetation index</i>
SNAP	<i>Sentinel application Plataform</i>
SPOT	<i>Satellite Pour l'Observation de la Terre</i>
SR	Sensoriamento remoto
TCH	Tonelada de cana por hectare
TM	<i>Tematic mapper</i>

SUMÁRIO

1. INTRODUÇÃO	13
1.1. Questões da pesquisa.....	16
1.2. Objetivos	17
1.3. Justificativa e relevância.....	17
1.4. Organização do trabalho	18
2. REFERÊNCIAL TEÓRICO/CONCEITUAL	19
2.1. A Geografia da Cana-de-açúcar	19
2.2. O agroecossistema canavieiro	21
2.3. Panorama da produção agrícola da cana-de-açúcar e o sensoriamento remoto	29
2.3.1. A agricultura de precisão (AP) e dados geoespaciais.....	32
2.3.2. Sensoriamento remoto aplicado na cana-de-açúcar	37
2.3.3. Característica da produção de cana-de-açúcar relevantes ao emprego de sensoriamento remoto	38
2.3.5. Identificação varietal	43
2.4. Classificação de imagens de satélite na agricultura.....	45
2.5. Classificadores <i>Randon Forest</i> , <i>Supporte Vector Machine</i> e <i>Neural Networks</i>	49
2.8. Estimativa de produtividade e imagens de satélite	56
2.9. A vinhaça e o ciclo da cana	58
3. MATERIAIS E MÉTODOS	63
3.1. Área de estudo	65
3.1.1. Dados auxiliares.....	67
3.1.2. Imagens e processamento de imagens.....	67
3.1.3. Médias de produção e dados de SR das safras recentes	69
3.1.4. Teste estatístico.....	69
3.2. Processo da classificação orientação orientado a objeto	71
3.2.1. Aquisição de dados.....	71
3.2.2. <i>Sentinel Application Platform (SNAP)</i>	71
3.2.3. <i>Orfeo ToolBox (OTB)</i>	72
3.2.4. Processamento	72
3.2.5. Separabilidade espectral (Se as classes são separáveis)	74
3.2.6. Segmentação	75
3.2.7. <i>Large Scale Mean Shift (LSMS)</i>	76
4. RESULTADOS	80
4.1. Avaliação dos entre diferentes sensores no monitoramento da fertirrigação	80

4.1.1.	Conclusão da correlação entregue número de corte e resposta espectral.....	82
4.1.2.	Avaliação comparativa entre as médias de dados SR e de campo dos anos subsequentes	83
4.2.	Classificação orientado a objeto aplicado no monitoramento da fertirrigação.....	86
5.	CONCLUSÃO	92
6.	REFERÊNCIAS BIBLIOGRÁFICAS	94

1. INTRODUÇÃO

Embora a produção de alimentos tenha dobrado nos últimos 30 anos, terá que dobrar novamente até 2050 para alimentar uma população esperada de 8,5 bilhões (WISE, 2013). Segundo estatísticas recentes, isso parece improvável, pois em 2000 a produção agrícola mundial cresceu apenas 1%, a menor desde o início dos anos 90. Dentro do cenário de evolução de produção agrícola, está inserido a cana-de-açúcar (ESTEVES, 2017). Para aumentar a produção agrícola, é necessário a combinação de vários fatores. Isso inclui um ambiente saudável e um planejamento agrícola sólido. Um ambiente saudável implica reduzir a erosão do solo causada pelo vento, pela água e pelo excesso de cultivo; proteger recursos hídricos finitos; e reduzir a poluição atmosférica, como a chuva ácida que afeta plantações e florestas. Igualmente importante é fazer o melhor uso das terras agrícolas (RIBEIRO, 2008).

A agricultura está desenvolvendo e transformando o campo com inovação e aplicação de tecnologia a partir de grandes investimentos para otimizar de forma sustentável a produção para conseguir atender uma demanda contínua mundial por alimentos (SILVEIRA, et al., 2005). Neste cenário, a cana-de-açúcar ocupa grande porções do espaço geográfico para a produção de alimentos e energia, que tem como demanda para ser sustentável o processo produtivo, aumentar a produtividade na mesma área cultivada. A cana-de-açúcar é um dos produtos cultivados em larga escala no Brasil e demanda informações sobre grandes áreas (> 50 mil hectares por unidade industrial de processamento de etanol e açúcar) onde a pesquisa com satélites oferece dados para subsidiar aplicação em formas de monitoramento para ganhos de produtividade (PEREIRA, et al., 2017).

Com o advento dos satélites, foi possível medir e estimar cada metros quadrado da superfície, com isso, estima-se mundialmente 1,53 bilhões de hectares em terras agricultáveis, equivalente a 12% da superfície do planeta (FAO, 2009). O mapeamento das terras agricultadas demonstra que 62% delas tem sido utilizada pela agricultura na produção de alimentação para humanos e animais. Contudo, para gerar somente a proteína alimentícia animal, o percentual é de 35%, mais da metade da área destinada para consumo de carne por humanos. Na produção de bioenergia apenas de 3 % é destinado (FOLEY et al. 2011; FAOSTAT, 2015).

A projeção global sobre a produção de alimentos é conhecida por meio de estudos e estimativas econômicas e de crescimento populacional. O ano de 2050 é um marco para segurança alimentar do planeta, pois nesse ano o consumo de alimentos será o dobro dos números atuais. Porém, existe a demanda ambiental e sustentável, que exige um controle sobre o crescimento produtivo sobre o ambiente, definindo que não poderemos desmatar tudo para

produção, pois é necessário atender também a questões sobre o aquecimento global. Essas conclusões miram para necessidade de produção vertical, o que significa produzir mais na mesma área, e isso só possível com agricultura de precisão (FOLEY et al., 2011; THE ROYAL SOCIETY, 2016).

Com o desenvolvimento crescente do Sensoriamento Remoto (SR), com histórico de mais de 40 anos com estudos e aplicação na agricultura, na última década houve uma disponibilidade de dados com maior capacidade de extrair informação da superfície terrestre, o que refletiu na ampliação das possibilidades de estudos e aplicações em agricultura (FORMAGGIO, A. R., & SANCHES, I. D. A. 2017).

Em 2004 foi feito um levantamento das áreas de tecnologias em que provavelmente haveria maiores investimentos nos 50 anos seguintes. Entre as áreas estariam nanotecnologias, biotecnologias e as geotecnologias, sendo que essa última envolve o desenvolvimento de satélites e Drones aplicados para o levantamento do espaço geográfico e a localização geoespacial (GEWIN, V., 2004).

Atualmente, após 16 anos da previsão de desenvolvimento científico no mercado de geotecnologias, a previsão vem se confirmando anualmente, através do desenvolvimento de novos satélites, com maior resolução espacial, temporal e espectral. Desses, alguns sistemas de satélites estão voltados para a agricultura. O lançamento do satélite Sentinel em 2016 transformou o uso na agricultura que, por meio do conjunto de dois satélites, plataforma Sentinel 2 A e B, permitiu uma revisita com 5 dias de intervalo e uma resolução espacial que varia de 10 a 60 metros. O período de 5 dias permite que a cultura agrícola seja monitorada com tempo suficiente para intervenção e ações no campo (VAN TRICHT, K., 2018).

Em produção agrícola de cana-de-açúcar o manejo ocorre durante todo ano, com janelas operacionais definidos de acordo com as características climáticas da região (OLIVEIRA FILHO, et al. 2015). As ações operacionais são divididas por atividades sequenciais que compreendem formação de lavoura, tratos culturais, plantio e colheita, que necessitam de monitoramento para avaliar a qualidade da execução. O método tradicional de monitoramento é realizado apenas de forma amostral, em campo.

Em muitas operações, como a fertirrigação (irrigação com vinhaça), não é possível garantir a qualidade da aplicação devido à dificuldade operacionais de avaliação. Identificar se o lançamento do líquido vinhaça foi realizado seguindo a medidas padronizadas com faixa de 60 metros de espaçamento entre as linhas de aplicação foi respeitada em área maior que 500 hectares.

Para solução de alguns desafios na agricultura, o campo da agricultura de precisão, atua dentro do conceito de realizar operações de forma precisa no quesito qualidade, quantidade e geograficamente posicionada. É na agricultura de precisão que o sensoriamento remoto fundamenta o conceito, devido a capacidade de identificar e mapear a variabilidade espacial da condição ou efeitos de um processo de manejo agrícola, seja precisão, recomendação ou avaliação.

Atualmente, as oportunidades de exploração dos dados de sensoriamento remoto na agricultura estão em conhecer os problemas na área agrícola operacional e aplicar métodos que extraiam produtos das imagens que tornem possível tomar decisões sobre o manejo agrícola. Mesmo com o mercado privado avançando, os dados espaciais de SR hegemonicamente mais utilizados em pesquisa na agricultura ainda são a plataforma Landsat, do programa espacial mais antigo do planeta feito pela NASA (*Nacional Aeronautics and Space Administration*) para imageamento e, mais recente, o programa espacial da ESA (*European Space Agency*).

Na agricultura a realidade de ocupação de grandes áreas torna cada vez mais desafiador monitorar e acompanhar o que o processo produtivo, com vistas à intervenção para se obter melhores resultados. Quando um problema é identificado, sendo ele uma irrigação errada ou um ataque de praga, na maioria das situações a ação sobre o ocorrido tem pouco efeito ou as perdas são irreversíveis. O sensoriamento remoto aplicado na agricultura tem a capacidade de remediar um problema em tempo hábil para se evitar perdas e ampliar os ganhos em muitos processos.

A agricultura está demandando e, para desenvolver soluções, o caminho é a construção de modelo e métodos aliados a condições de manejo que permitam análises precisas para a tomada de decisão. Os processos agrícolas têm como desafio ao monitoramento a distribuição espacial, em larga escala territorial, as especificidades temporais, a identificação das janelas específicas de intervenção, que variam de acordo com as condições edafoclimáticas. A cana-de-açúcar, cultura que é produzida em todo território nacional, produz a vinhaça, que é utilizada como fertirrigação. A fertirrigação tem características de manejo que dependem de um controle de quando e onde foi aplicada.

O controle da qualidade da fertirrigação está intrinsicamente ligado à agricultura de precisão, pois requer intervalo de tempo, espaçamento preciso, quantidade mínima e operação de equipamentos de forma adequada. Como atributo de impacto, a fertirrigação tem duas funções cruciais para processo de produção da cana: irrigar nos meses de seca e lançar fertilizantes que estão presentes na vinhaça. Vale ressaltar que as áreas fertirrigadas correspondem a cerca de 30% da área do total de produção de uma usina, e nessa área não é

feita a aplicação de adubo por meios tradicionais, mas sim somente é aplicado a vinhaça como única fonte de nutrientes.

O delineamento experimental é a área geográfica denominada no manejo agrônomo como bacia de vinhaça (fazendas próximas à unidade industrial que recebem aplicação de vinhaça). Essas fazendas correspondem a uma área de aproximadamente 30 mil hectares, que por meio de tubulações e canais, são irrigadas com o resíduo da indústria (vinhaça). As zonas de lançamento e aplicação da vinhaça estão localizadas nas fazendas em torno da planta industrial, em um raio de 10 a 15 km de distância da usina.

As zonas de aplicação da vinhaça, por meio do processo de fertirrigação por aspersão, são subdivididas em talhões, e o controle da qualidade na aplicação da fertirrigação é de difícil avaliação, chegando a ser impossível em algumas áreas sem o apoio de alguma tecnologia. A cana depende desse processo para se desenvolver, mas somente quando a planta começa a crescer é que é possível avaliar os resultados da fertirrigação.

Quando é feita alguma análise e se consegue avaliar a qualidade, o tempo para uma operação de correção não é mais possível, porque demanda em torno de 15 a 20 dias para que a resposta da planta demonstre o problema. Nesse prazo a estrutura de fertirrigação já saiu da área e foi para outra.

1.1. Questões da pesquisa

Diante do exposto, parte-se do suposto que o sensoriamento remoto, Por satélite, é eficaz fonte de dados para a gestão controlada do processo de fertirrigação que resulta em agricultura de precisão. Assim, considera-se que avaliar possibilidades metodológicas e técnicas do processamento também permitirá trazer meios para solução do problema da falta de monitoramento adequado. Nesse sentido, algumas questões subsequentes se apresentam: a) a capacidade de aplicação de imagens de satélite em na avaliação e qualidade permite um controle que promove a agricultura de precisão? b) a relação de produtividade, fertirrigação e variação nos índices de vegetação têm correlações em diferentes configurações de produtividade? C) É possível monitorar aplicação da fertirrigação com sensoriamento remoto?

¹ Talhão: Unidade de divisão da fazenda em partes com tamanho médio de 20 hectares para manejo e produção agrícola. Os talhões em sua predominância tem forma geométrica quadrada ou retangular e o espaçamento entre os talhões é denominado carreadores (Estradas para tráfego entre os talhões).

1.2. Objetivos

Com base nas questões expostas no item anterior, o objetivo geral dessa pesquisa de tese é analisar e aplicar dados de sensoriamento remoto no manejo agrônômico em território de produção com cana-de-açúcar fertirrigada por vinhaça.

Como objetivos específicos, apresentam-se:

- Avaliar a capacidade de diferentes sensores remotos na identificação e mapeamento de áreas fertirrigada com vinhaça;
- Comparar a correlação da fertirrigação com histórico de produtividade e os impactos gerados;
- Elaborar um modelo metodológico para monitoramento e controle das áreas que recebem fertirrigação com tempo reposta para ação corretiva operacional.

1.3. Justificativa e relevância

Para pesquisas e estudos com agricultura de precisão no monitoramento, em controle e distribuição geográfica complexos, são necessários desenvolvimento e aplicação de tecnologias que forneçam dados espaciais de forma periódica e que abranjam grandes áreas. A geografia em qualquer empreendimento que dependa da escala territorial/espacial precisa considerar análise das variáveis geográficas com técnicas para o sucesso de uma atividade, por exemplo a agricultura. No manejo agrícola o mapeamento e monitoramento do espaço geográfico não é considerado como pilar do processo como deveria ser e, existe uma lacuna ainda na atuação agrônômica de uso da geografia como parte fundamental do processo operacional, assim, muitas formas de manejo agrônômico sobre problemas de produtividade, por não utilizarem as ferramentas que tratam o meio geográfico parte do processo, tem a produção afetada por fatores desconsiderados na análise. Atualmente a disponibilidade de dados é grande no campo do sensoriamento remoto, devido aos satélites, constelação GNSS e mais recentemente o uso de drones. Contudo, existe uma lacuna entre a disponibilidade de dados e o desenvolvimento de estudos metodologicamente aplicados de acordo com a particularidade de cada processo na agricultura.

Uma aplicação que demonstra tal diferença é a geração de índices de vegetação para estudos agrícolas. O NDVI (*Normalized Difference Vegetation Index*) tem sido referenciado desde os anos 80. Porém, somente nos últimos 10 anos foram realizados estudos de aplicações do NDVI com precisão e escala temporal adequados ao manejo agrícola, na tomada de decisão

diária (YENGOH, et al. 2015). O estudo se fundamenta na necessidade de aplicações práticas delineadas com a realidade operacional da cultura agrícola. Acredita-se que para discriminar e decodificar as características operacionais e respostas que o sensoriamento remoto pode inferir e responder, são necessários estudos *in situ*.

Concomitante ao isso, a construção de uma base de dados sólida, precisa e com qualidade espacial, é crucial para desenvolvimento do setor agroindustrial. Tendo ciência da importância da geotecnologia, Câmara et al. (2001) cita que se o “onde” é importante para o seu negócio, a geotecnologia é a sua ferramenta principal de trabalho. Alinhado com esse raciocínio a agricultura depende totalmente do “onde” e das medidas espaciais com precisão, por ser todo o processo construído na relação entre produto e a quantidades por área. Assim, todo cálculo econômico depende de mapeamento de área correto, a exemplo de toneladas colhida por hectares, insumos aplicados por hectares, toneladas de açúcar por hectare, máquinas por hectare e o objeto da análise: fertirrigação por hectare. Atualmente não existe uma ferramenta de análise que consiga monitorar a fertirrigação adequadamente. A dependência da avaliação da qualidade na aplicação é feita de forma amostral e o sensoriamento remoto pode suprir essa etapa.

Os índices de vegetação, apesar de muito difundidos e conhecidos, precisam ser adaptados ou preparados para atenderem a repostas espectrais de problemas na agricultura (CANDIAGO, et al. 2015). Para mudar dessa realidade, dependemos de estudos que considerem a realidade de campo, para se extrair repostas específicas usando o sensoriamento remoto. O modelo de classificação orientado ao objeto, no caso da agricultura, pode ser aplicado em centenas de situações (RAJESH, D. 2011). Nesse sentido, serão analisados métodos com sensoriamento remoto para darem respostas que a prática da agricultura ainda não tem. Nesse cenário, com base em técnicas e métodos de sensoriamento remoto, será avaliada a capacidade de aplicação no manejo, controle, avaliação e reposição da produção de cana fertirrigada.

1.4. Organização do trabalho

O trabalho apresenta inicialmente o referencial teórico, descrevendo um panorama sobre a geografia da cana-de-açúcar as características do manejo e da produção. A segunda parte aborda as tecnologias aplicadas na produção da cana de açúcar, caracterizando a agricultura de precisão e a evolução recente no Brasil. Na terceira parte há uma discussão sobre inovação tecnológica na agricultura de precisão o advento das geotecnologias, com ênfase no histórico e avanço do sensoriamento remoto e nas diversas aplicações na agricultura. Cabe ressaltar que o

recorte temporal das inovações de SR em agricultura, o grande salto, foi dos últimos 10 anos, com o avanço e demanda por concretização de diversas hipóteses com aplicações de sensoriamento remoto em agricultura.

A sequência do trabalho, apresenta-se o caminho metodológico do trabalho (Materiais e Métodos), que descreve os resultados da pesquisa, discriminado em partes de análise e interpretação. Nos resultados desse trabalho foi demonstrado cerca de 90% das análises do desenvolvimento da tese. Os resultados alcançados se referem ao estudo da correlação entre dados de sensoriamento remoto, qualidade de aplicação da fertirrigação e os reflexos nas produtividades. O modelo de classificação orientado a objeto das áreas fertirrigação também foi realizado na área de teste. Nesse mesmo item, foram extraídas e apresentadas estatísticas sobre os valores dos pixels dos índices de vegetação processados com as fotos, correlacionados com os dados de satélite. Finalmente, foram discutidos resultados obtidos e indicados possíveis e necessários desdobramentos futuros.

2. REFERENCIAL TEÓRICO/CONCEITUAL

No que tange a informações da pesquisa, o referencial bibliográfico utilizado oferece um base teórico/conceitual que sustenta toda a argumentação lógica da pesquisa aqui conduzida. A universo temático da pesquisa envolve o sensoriamento remoto, especificamente aqueles utilizados na agricultura de precisão, o manejo da fertirrigação na agricultura. Nos permitem avançar no que se define como a geografia da cana-de-açúcar.

2.1. A Geografia da Cana-de-açúcar

Mais do que qualquer outra espécie vegetal, a cana-de-açúcar foi uma das bases de construção do território brasileiro. Ainda que fossem os bandeirantes e outros pioneiros a desbravarem o interior do continente, a partir do Século XVII, a lavoura canavieira é que possibilitou, logo no primeiro século de colonização portuguesa, o crescimento demográfico e econômico dos primeiros assentamentos agrícolas de estilo europeu, na costa, que funcionaram como centros de controle e expansão territorial (PRADO JÚNIOR, 1945a; FURTADO, 1971; SCHWARTZ, 1988; FREYRE, 2004; CABRAL, 2014)

As raízes da geografia canavieira colonial modelaram grande parte da história subsequente do Brasil e os seus resquícios podem ser encontrados, ainda hoje, em inúmeras paisagens e manifestações culturais do País (IBGE, 2017).

Atualmente, a cana-de-açúcar é o terceiro maior cultivo brasileiro em área plantada, atrás apenas da soja e do milho. Em 2016, os canaviais ocupavam 10,5 milhões de hectares, ou seja, 13,5% do total nacional de área plantada no País (TEIXEIRA & HESPANHOL, 2016). Estima-se que a cadeia produtiva da cana-de-açúcar tenha gerado, somente no terceiro trimestre de 2016, um produto de R\$ 152,3 bilhões, mais de 1/5 do Produto Interno Bruto - PIB do agronegócio brasileiro, naquele período (FANTINATTI, 2021).

A cana-de-açúcar é produzida no Brasil em grande escala a partir dos anos 70, tornando-se o maior produtor do mundo na década de 1980, alcançando em 2020 754,9 milhões de toneladas, tornando-se cultura com terceira posição na ocupação de área para produção. A média nacional de produtividade é 74 de TCH (Toneladas por hectares), superior à média mundial de 68,3 toneladas/hectares. Está presente em 3.276 municípios (DIAS, 2021).

Entre os produtos extraídos do processamento da cana estão o etanol e o açúcar (branco, líquido ou refinado). A quantidade de sacarose é o foco do cultivo, pois quanto maior a sacarose, maior é a capacidade de se extrair os subprodutos. Com a sacarose são feitos todos os processos posteriores. Produtos de menor expressão comercial, tais como melaço, açúcar mascavo, e rapadura, são produzidos em pequenas moendas, com estrutura familiar. Os resíduos do processamento da cana são o bagaço (fibra vegetal que retorna no processo industrial como combustível na caldeira de aquecimento), a vinhaça (usada com fertilizante e irrigação substituindo a água no período seco), a torta de filtro (resíduo pastoso de matéria orgânica que é aplicado no fundo do sulco durante o plantio) e a cinza da queima da caldeira (lançada e misturada ao solo para efeito de enriquecer com minerais) (ALVES et. al., 2021).

Carro-chefe da economia de inúmeros municípios do País, o setor sucroenergético é apontado, na literatura, como importante modelador do ambiente ecológico, das relações de trabalho e da qualidade de vida, em âmbito local e regional (ANDRADE, 1994; MACHADO et al., 2015, 2017; CASTILLO, 2015).

O cultivo mecanizado de cana precisa ser realizado em relevo com pouca variação topográfica, com declividades abaixo dos 12%, a uma distância média de 35 quilômetros da usina (unidade industrial), com fontes hídricas, rios e córregos, com capacidade de vazão para atender a indústria e a irrigação e com logística de transporte favorável ao escoamento da produção (IBGE, 2017).

A cadeia produtiva do setor sucroenergético depende da distribuição espacial da produção, ou seja, é fundamental definir o arranjo geográfico para se instalar uma planta de processamento. O planejamento do escoamento da produção, a logística de transporte da colheita, a identificação de regiões com mãos de obra disponível, a presença de usina concorrente próxima e a disputa com outras culturas impacta diretamente na atividade econômica (IBGE. 2017).

Outro cenário que vem crescendo nos últimos 8 anos é a nova ordem territorial e logística da produção de etanol em usinas, que antes eram somente de processamento de cana, mas agora estão construindo planta industrial de processamento de milho para extração de etanol, óleo e ração animal. O mercado está em plena diversificação, entrando no mercado de consumo de grãos e extraíndo produto da cana e do milho no mesmo processo industrial (MILANEZ, 2014).

Várias empresas estão investindo na ampliação do processo industrial, o que expande o território de exploração para produção de etanol para outras regiões do Brasil. Nesse sentido, as usinas de cana estão se tornando híbridas, processando cana e milho, transformando a usina que processava cana durante 8 meses por ano para 12 meses de atividades (MILANEZ, 2014).

2.2. O agro ecossistema canavieiro

A cana-de-açúcar é uma gramínea perene pertencente à mesma família do trigo, do milho e da aveia, que são fundamentais para as populações humanas. Os atributos e potencialidades da cana-de-açúcar – muitas delas modificadas pela manipulação genética – capacitaram os seres humanos a construir certas geografias históricas, por meio do que é comumente chamado de agro ecossistema. São ecossistemas reorganizados por meio da recomposição das espécies constituintes e, conseqüentemente, da cadeia trófica de um pedaço da biosfera, com o objetivo de atender a fins humanos, como alimentação e vestuário, muitas vezes acoplados a sistemas industriais de beneficiamento. Geralmente, são sistemas de exportação, no sentido de que servem a populações humanas distantes do lugar original de produção (WORSTER, 2003).

A eficiência econômica da cana-de açúcar é de alto valor agregado, com três fatores econômicos que definem a alta rentabilidade. A primeira é alta produtividade, onde a cana-de-açúcar pode chegar até 10 ou 12 anos de colheita a mesma planta, constituindo um significativo banco de energia biológica, que pode chegar o acúmulo de mais de 800 toneladas por hectare no período de 10 anos. Vale ressaltar que após o quinto ano de produção há retorno financeiro

garantido, mantendo a média de 70 toneladas por hectares (CABRAL, 2014). Dependendo da eficiência na aplicação de insumos para se tratar o canavial e os produtos gerados (açúcar, melado, etanol, energia, ração animal e óleo) eles podem ser processados localmente na usina. É indicado que eles fiquem localizado geograficamente de forma central em relação às áreas cultivada com cana, de modo a permitirem o uso eficiente dos insumos agrícolas (águas, fertilizantes, pesticidas, trabalho), e mais atualmente de biogás (MOORE; PATERSON; TEW, 2014; DA SILVA, et al. 2021).

Diferentemente de outros cultivos, como os de cereais, o cultivo da cana-de-açúcar é realizado por meio vegetativo, ou seja, o que se planta no solo não são sementes, mas pedaços de indivíduos adultos, chamados “toletes” ou “olhaduras” (Figura 1). Cada tolete, com um comprimento entre 30 e 50 centímetros, possui até quatro gemas de brotação, constituídas por tecidos vegetais latentes e reservas nutricionais.

De cada uma dessas gemas brotam diversos perfilho (novos colmos), formando uma touceira (AUDE, 1993). Em outras palavras, a gema é uma espécie de colmo potencial. Em condições favoráveis – dentre as quais a principal é a disponibilidade de água –, a gema é ativada sob a ação de enzimas e reguladores de crescimento, desenvolvendo-se a partir das reservas nutricionais (DILLEWINJ, 1952 apud LANDELL et al., 2012). Para se reduzir a quantidade de cana picada nos plantios, desenvolveu-se mais recentemente a tecnologia de mudas pré-brotadas. Em vez de toletes, plantam-se indivíduos já brotados com a ajuda de adubos e fertilizantes, além de tratados com métodos fitossanitários (LANDELL et al., 2012).




Figura 1 - Tolete de cana-de-açúcar. Fonte: KOEHLER et al. 2009

A cana tem origem no do sudeste asiático, e com as troca e desenvolvimento durante longo período antes de chegar ao continente sul-americano. A cana-de-açúcar foi introduzida no Brasil com a chagadas dos portugueses, no período de 1530, que promoveram um fluxo logístico a partir da ilha da Madeira (CABRAL, 2014). Nos primeiros séculos da colonização portuguesa, ela foi plantada nas várzeas das planícies da costa atlântica, sobretudo na Região Nordeste, onde a produção de açúcar ajudou a modificar toda a ecologia regional (FREYRE, 2004). No Século XVIII, a região de Campos dos Goytacazes, no Rio de Janeiro, despontou como grande produtora (MENDES, 1950), bem como a área em torno de Campinas (São Paulo), a primeira grande região exportadora de açúcar do planalto (PETRONE, 1968).

A primeira instituição a realizar pesquisas com cana-de-açúcar foi o Instituto Agrônomo de Campinas - IAC, fundado pelo imperador D. Pedro II em 1887. A irrupção de sérias pragas agrícolas, como o chamado “mosaico da cana”, motivou a reorganização da experimentação biológica, a partir da década de 1930.

Atualmente a cana ocupa todo o território nacional (Figura 2). A sua importância e a fica evidenciada no ranking de distribuição da produção entre os estados, demonstrando que muitas regiões e municípios do país são sustentados pelo seguimento econômico (Figura 3).

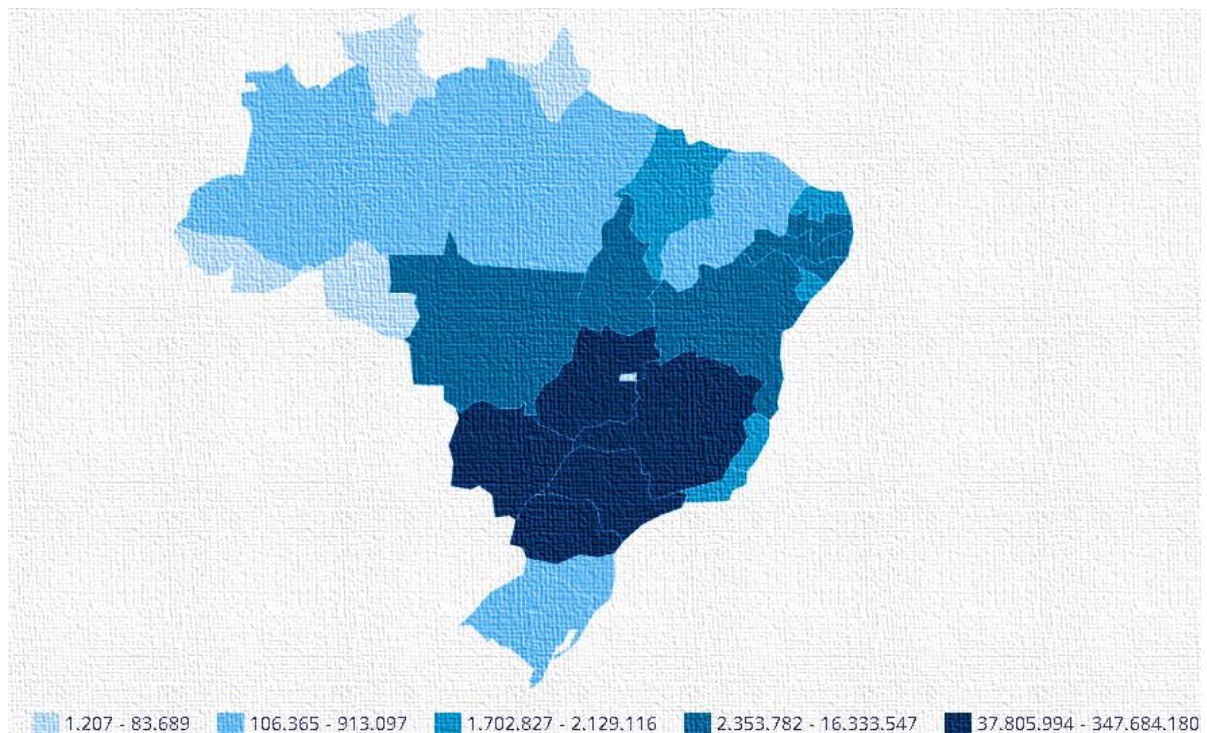


Figura 2-Representação cartograma da cana-de-açúcar no Brasil por quantidade produzida em toneladas. Fonte: (IBGE, 2019).




Figura 3- Ranking cana-de-açúcar dos Estados do Brasil por quantidade produzida em toneladas. Fonte (IBGE, 2019).

Embora tenham acontecido esforços de descentralização, essa reorganização manteve a maior parte dos cientistas e dos equipamentos de pesquisa no Estado de São Paulo, o que ajudou a alçar o estado à posição de maior produtor de cana do País, no início dos anos 1950 (CARVALHO; FURTADO, 2013).

O sistema de cultivo mais comum é aquele em que se permite um ciclo vegetativo de 18 meses, chamado de cana de ano-e-meio. Um segundo sistema de cultivo utiliza um ciclo de apenas 12 meses, no caso de grandes áreas de plantio, pois facilita o gerenciamento e otimiza a utilização de máquinas e mão-de-obra. Neste caso, costuma-se plantar na primavera, entre outubro e novembro, para se colher na primavera seguinte. Finalmente, há a possibilidade de se plantar no inverno, com aplicação de torta de filtro, que contém cerca de 70% a 80% de umidade e compensa a estiagem (ROSSETTO; SANTIAGO, 2015). Após o primeiro corte, que corresponde à chamada cana-planta, os canaviais podem ser colhidos novamente por diversos anos seguidos. O número de colheitas varia de região para região, entre um mínimo de duas ou três, até 10, em áreas especialmente produtivas. Essas rebrotas colhidas são chamadas de cana-soca.

No Brasil, a principal variável regional que influencia no período de plantio de cana-de-açúcar é a sazonalidade pluviométrica, embora as mudanças de temperatura também sejam consideradas pelos produtores (Tabela 1) (Figura 4). O território brasileiro possui climas regionais com diferenças substanciais quanto à concentração estacional da precipitação atmosférica. Segundo Zullo Júnior e outros (2010 apud CARVALHO; FURTADO, 2013), essa variabilidade espacial das condições climáticas constitui uma vantagem comparativa do Brasil, já que o território possibilita dois grandes padrões de colheita anual: de maio a dezembro, no Centro-Sul, e de setembro a abril, nas Regiões Norte e Nordeste. Enquanto, no Nordeste Oriental, o máximo de precipitação ocorre no outono e começo do inverno, na Região Sudeste,

o pico pluviométrico ocorre no verão (NIMER, 1979). Ainda que a irrigação possa corrigir déficits hídricos, essa tecnologia eleva os custos da empresa agrícola. Assim, quanto mais o cultivo usa a água de precipitação, melhor para a lucratividade.

Tabela 1-Períodos da safra de *cana-de-açúcar* no centro sul do Brasil – Fonte: O autor


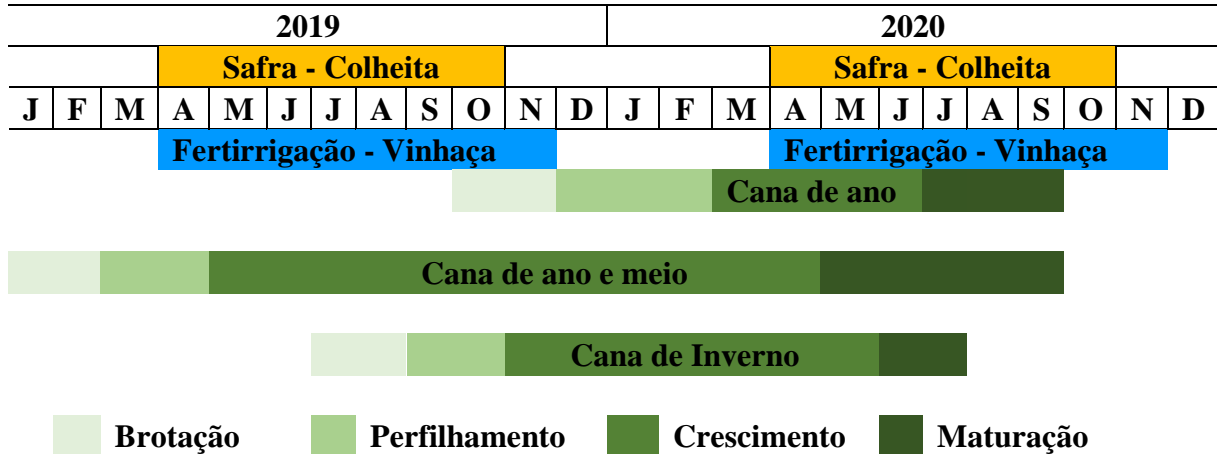


Figura 4 - Média anual de precipitação na região da área de estudo, sul de Goiás. Fonte: (IBGE, 2019).

Quando moderada, a deficiência hídrica sazonal é benéfica para o cultivo de cana-de-açúcar, pois serve como gatilho ambiental para a interrupção do crescimento vegetativo e início da concentração de sacarose nos colmos. No entanto, quando o déficit hídrico anual supera os 180 mm, a irrigação é necessária para assegurar a rebrota dos canaviais, a chamada soca; quando o déficit supera os 400 mm anuais, faz-se necessária irrigação intensiva (ZULLO JÚNIOR et al.,2010 apud CARVALHO; FURTADO, 2013). Estudos experimentais indicam que a irrigação aumenta, consideravelmente, a produtividade dos campos de cana, sobretudo em áreas

de Cerrado (GAVA et al., 2011). No entanto, os dados do Censo Agropecuário 2006 (VEDANA et al, 2017) mostram que a maior parte dos estabelecimentos de cana, em todo o Brasil, não utilizavam irrigação naquele ano.

Distribuídos pelo Território Nacional, sem seguir um padrão geográfico aparente, há municípios isolados e pequenos conjuntos de municípios cuja maioria dos estabelecimentos canavieiros utiliza irrigação. Provavelmente, essas pequenas concentrações de irrigação respondem a condições locais específicas, tanto ambientais quanto empresariais.

Outras práticas capital-intensivas que modelam criticamente o agro ecossistema canavieiro incluem a adubação e o uso de agrotóxicos. A adubação corrige certos atributos do solo, visando ao incremento de sua fertilidade. Os corretivos de fertilidade mais comuns da lavoura canavieira são o calcário, o gesso e o fosfato, substâncias adicionadas ao solo no período seco antes do início do plantio (VITTI; MAZZA, 2002). Os estágios da cana dependem fortemente dos nutrientes lançados no solo, pois a planta tem um crescimento muito rápido em 1 ano pode chegar a 6 metros de altura com uma densidade de mais 100 toneladas por hectares. Na figura 5 é apresentado o estágio da cana.




Figura 5-Fases fenológicas da cana-de-açúcar Fonte: Sobrinho (2019).

Além da aplicação desses produtos químicos, usam-se adubos orgânicos, sendo que os dois principais são a torta de filtro e a vinhaça, ambos produzidos como resíduos da fabricação de açúcar e álcool (etanol).

A torta é um resíduo sólido que, por ser mais rico em fósforo e cálcio, é empregado principalmente na renovação de plantações (cana-planta). A vinhaça é um líquido marrom-escuro que exala forte odor e cujas características químicas são baixos pH, alto teor de potássio e alta carga de matéria orgânica, sendo mais utilizada nos campos rebrotados. Estudos experimentais indicam que tanto a torta quanto a “fertirrigação” com vinhaça (Figura 6) aumentam a produtividade canavieira (FRAVET et al., 2010; SILVA et al., 2014).

Por seu turno, os agrotóxicos objetivam assegurar a dominância biológica da cana, nas áreas de plantio, bem como protegê-la contra predadores e doenças. Os herbicidas são produtos químicos que previnem o chamado mato, ou seja, plantas daninhas como a tiririca, a grama-seda e o capim-colonião, que se estabelecem entre as fileiras plantadas e competem com a cana por água, luz e nutrientes (além disso, algumas delas atuam por alopatia, que é a liberação de substâncias que inibem o desenvolvimento da cana).

Os herbicidas podem ser aplicados tanto antes quanto depois da emergência das plantas invasoras. Há diversos tipos de herbicida, conforme a atuação bioquímica sobre as ervas daninhas: certos produtos desorganizam o crescimento inicial, outros dificultam a fotossíntese, enquanto outros inibem a síntese de aminoácidos etc. (VICTORIA FILHO; CHRISTOFFOLETI, 2004).



Figura 6 - Área de cana planta fertirrigação com vinhaça. Fonte: O autor.

O mesmo acontece com o uso da vinhaça utilizada na fertirrigação, que pode causar impacto no lençol freático e corpos d'água. Entre os anos de 2006 e 2015 observou-se grande expansão a partir do núcleo paulista em direção norte-noroeste e oeste-sudoeste, incorporando, definitivamente, o Triângulo Mineiro, o sul goiano e o centro-sul do Estado do Mato Grosso do Sul em um enorme arco quase contínuo de municípios canavieiros, a maioria deles no Cerrado (CASTILLO, 2015). Um dos problemas do cultivo da cana era o manejo com queimada, necessário principalmente para colheita manual, para “limpar” a massa vegetal de palha que atrapalha o trabalhador rural adentrada para realizar o corte da cana. Um fator importante no Estado de São Paulo foi a Lei estadual n. 11.241, de 19.09.2002, que proibiu o uso do fogo como método de manejo para o corte da cana-de-açúcar no estado (HAMADA, 2003)

A lei estabeleceu um cronograma de redução progressiva da prática da queima segundo as possibilidades de mecanização do corte, nas áreas de cultivo. Nas áreas mecanizáveis, a queima deveria ser eliminada até 2014. Por outro lado, nas áreas não mecanizáveis, bem como naquelas com declividade superior a 12% ou em propriedades menores do que 150 hectares, a eliminação da queima começaria somente em 2011 e se completaria em 2031 (SÃO PAULO, 2002). Favorecendo os investimentos em mecanização, esse marco jurídico modificou as condições da decisão locacional das empresas sucroenergéticas.

As antigas áreas de solos férteis, mas de relevo ondulado – como a Depressão Periférica e as Cuestas Basálticas de São Paulo – tornaram-se menos vantajosas do que áreas de solos menos naturalmente férteis, mas extremamente planos e mais resistentes à compactação, como os latossolos vermelhos do sul de Goiás. No Estado de Goiás, o governo estadual concedeu incentivos fiscais para a instalação de usinas, além de adotar políticas de melhoramento das estradas do interior (MESQUITA, 2015). O avanço para o centro-oeste demonstra claramente ser o impulsionador do crescimento da produção nacional (Figura 7).

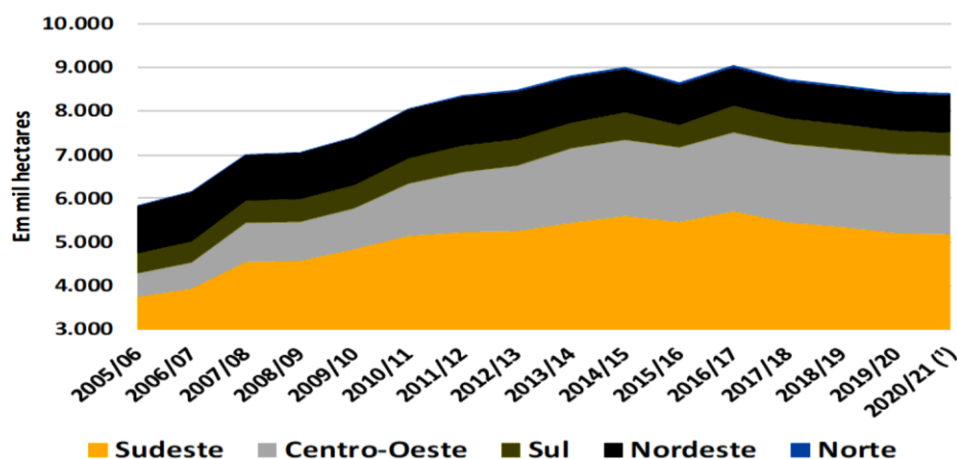


Figura 7 - Evolução da safra de cana-de-açúcar. Fonte: CONAB, 2020.

2.3. Panorama da produção agrícola da cana-de-açúcar e o sensoriamento remoto

O avanço da agricultura em territórios geograficamente distintos e com a necessidade de dobrar a produção, terá sucesso somente com o avanço tecnológico. Parte deste avanço virá da aplicação de dados extraídos por Sensoriamento Remoto, tanto orbital e como por drones. Os crescentes e multimilionários investimentos realizados por governos e empresas no desenvolvimento e lançamento de novos satélites descrevem como é fundamental essa tecnologia na agricultura, para que as técnicas de agricultura de precisão sejam cada vez mais assertivas.

A produção de cana-de-açúcar é um dos maiores setores do agronegócio no Brasil e encaixa-se perfeitamente no processo de demanda por uso de imagens orbitais, principalmente pela produção ser concentrada. O país é o maior produtor do mundo e isso destaca a importância da agroindústria sucroalcooleira perante a demanda do planeta. A evidência da importância está no cenário de um território que tem a matriz energética diversificada, e a cana representa 18% (DA SILVA, H. 2020).

O setor sucroenergético brasileiro com a produção de cana tem como principais produtos a geração de etanol, açúcar, energia elétrica e fertilizante. O etanol transforma e diversifica a matriz energética do país, o açúcar abastece o mercado nacional e o excedente tem mercado praticamente sem concorrência para exportação. A energia elétrica é vendida para ao sistema nacional de distribuição de energia e o fertilizante é produzido por meio do resíduo denominado vinhaça. A energia elétrica é gerada devido a produção de resíduo da biomassa da cana, o bagaço, que se transforma em matéria prima para as caldeiras e torna todo o processo industrial autossuficiente em energia renovável (MILANEZ e Nyko,2012).

A produção de cana demanda para cada planta industrial de processamento, uma área entre 30 e 60 mil hectares de território agricultável. Na produção em grande escala de extensão geográfica, exige operações 24 horas por dia durante toda a safra. Principais etapas de operação, são: Arrendamento, preparo de solo, plantio, tratamentos culturais e colheita. Durante a safra as condições físicas e de manejo variam de acordo com característica de cada fazenda ou do talhão (RODRIGUES e ORTIZ, 2006).

O sensoriamento remoto (SR) é aplicado desde anos 70 em agricultura, utilizando imagens orbitais, devido o advento do programa Landsat. Atualmente, 40 anos depois, os satélites avançaram tecnologicamente em resolução espacial, temporal, espectral e radiometria que ampliou a capacidade de aplicação na agricultura. As pesquisas nos últimos 4 anos avançaram em na construção de produtos e modelos aplicado com grande nível de detalhe,

conforme, Som-ard (2021), Leonardo, F. (2021). Molijn, Ramses A. (2019) Dubey, S.K. (2018), Carlos H. W. S. (2017) abordaram aplicações de SR no setor agrícola, contudo, ainda existem muitos desafios e melhorias de modelos e aplicações.

Para Cuadra (2020), aliado ao processo de novas plataformas de dados por SR e, o desenvolvimento crescente dessas tecnologias, abre mais janelas para pesquisa em territórios de produção agrícola e amplia a capacidade de aplicação de modelos e, conseqüentemente, auxilia na maior produção de alimentos.

Na cana-de-açúcar há grandes desafios para se explorar imagens de satélites no manejo agrônômico. Faltam modelos aplicados à realidade de campo. Empresas de produção de cana estão descobrindo, nos últimos 10 anos, as aplicações de SR como parte do suporte no manejo da produção, com a criação de setores de geotecnologias inseridos nos processos. Esse é um fato demonstrado no uso de imagens orbitais e, nos últimos 5 anos, no uso dos drones. No Brasil o mercado agrícola é o maior impulsionador das aeronaves remotamente pilotada (RPA) atualmente (de Oliveira, 2020).

A realidade operacional incentiva que as pesquisas e os novos estudos de SR para agricultura sejam elaborados de forma contínua (BENARDINI, 2014). A agricultura de precisão é um exemplo claro, que evolui a cada ano, e o SR está inserido nesse contexto, pois trata o manejo agrícola dividido em células geográficas de acordo com a resolução espacial do sensor, ou seja, o tamanho do pixel passar a ser a unidade de análise. Comparando com a unidade de manejo na cana-de-açúcar, que na agricultura é o talhão, para o SR ela é o pixel. No SR um pixel, por exemplo, do satélite Sentinel 2 de 10 metros, torna-se a unidade de análise e define a aplicação de SR na agricultura de precisão.

A sustentabilidade do meio ambiente e o aumento de produtividade no setor agrícola é uma demanda constante, e o SR tem a capacidade de ampliar a ação dos dois temas. Com a aplicação de SR, o tempo resposta para uma ação é maior e mais precisa que qualquer método de campo adotado. Esse fator direciona as ações do dia a dia (HUNT JR, 2018).

Uma das ações é a aplicação de fertirrigação e a irrigação, que são dois processos iguais, mas com produtos diferentes. Os dois processos são aplicados de acordo com o planejamento agrícola. O lançamento é realizado durante 8 a 9 meses do ano. A execução desse processo segue um plano de manejo e um plano operacional, de modo que qualquer variabilidade na execução interfere na reposta do desenvolvimento da planta (BRAGA et al, 2011).

A fertirrigação é feita com vinhaça e a irrigação com água, o que apresenta um desafio: monitorar a qualidade da aplicação e os seus efeitos em áreas com mais de mil talhões entre 15 e 60 hectares distribuídos geograficamente em um raio de 50 a 100 km (ROCHA, 2012). A

capacidade do monitoramento pelo método tradicional (visita do avaliador em campo), é possível somente por meio de amostragem, que em produção da cana representa de forma deficiente.

Neste contexto, para Anziliero (2021), um monitoramento e avaliação por SR pode fornecer uma avaliação precisa e com tempo de resposta capaz de diminuir a perda de produtividade e os riscos ambientais das operações agrícolas. Os riscos ambientais monitorados são a proteção de mananciais, vegetação ripária, nascentes e áreas de preservação.

A fertirrigação é um processo realizado com o resíduo do processo industrial, que gera a vinhaça, um líquido que sobra após a fermentação para geração de etanol, com a relação de 1 litro de etanol produzido para 12 litros de vinhaça. Esse resíduo é transformado em fertilizante ao ser lançado na área de cultivo que devido a cor ao atingir a superfície da palha e altera a resposta da superfície permitindo a identificação pelo satélite (PACHECO, & HOFF, 2013).

A vinhaça contém uma grande quantidade de elementos químicos que servem com fertilizantes, os principais são potássio e o nitrogênio. O SR e as plataformas dos novos satélites fornecem o potencial para monitorar e extrair informações para diagnósticos na agricultura de precisão. A agricultura de precisão é um termo difundido apenas nos últimos 25 anos (MOLIN, 2015), que trouxe para agricultura uma forma de ampliar a demanda mundial por segurança alimentar de forma sustentável. Definir e aplicar métodos para consumir menos recursos e produzir mais sem a necessidade de crescimento horizontal é chave do desenvolvimento da agricultura de precisão. O SR encaixou de forma perfeita na agricultura e transformou-se em uma subsídio para agricultura de precisão.

Monitorar grandes áreas, identificar as necessidades de manejo, com capacidade de revisita diária, está transformando o SR um aliado com a capacidade de dar repostas para agricultura com uma velocidade suficiente para ampliar produtividade com capacidade de extrair informação menor que 100 m². Esse processo torna a SR um elemento chave dentro da agricultura de precisão, cobrindo áreas em escala regional com detalhamento dentro do talhão (SHEFFIELD, 2018).

Dados de satélites óticos permitem uma avaliação mais utilizado do ponto de vista de aplicação, já que é o modelo de dado mais aplicado em agricultura. Contudo, a evolução e acessibilidade dos dados de radar orbital faz presente e indispensável para estudo em agricultura, pois os meses chuvoso, com maior cobertura de nuvens, são os meses de maior intensidade de plantio de cana, onde os satélites óticos ficam limitados (KAMILARES & PRENAFETA, 2018).

O desafio é a aplicação de SR para correlação atividades operacionais realizadas durante o processo de produção de cana em diferentes condições de ambiente geográfico e de manejo. A proposta de Abdel-Rahman (2008), revisou e abordou uma análise exploratória de dados óticos e radar na capacidade as variações espectrais, identificação e mensurar qualitativamente os processos de fertirrigação, plantio e colheita na cana-de-açúcar (Figura 8).



Figura 8 - Ilustração da pulverização da vinhaça do canal (a) ao hidro-roll (b) para o campo (c). Fonte: O Autor.

2.3.1. A agricultura de precisão (AP) e dados geoespaciais

O Ministério da Agricultura, Pecuária e Abastecimento (Mapa), ao instituir a Comissão Brasileira de Agricultura de Precisão (CBAP) em 2012, definiu a Agricultura de Precisão como “um sistema de gerenciamento agrícola baseada na variação espacial e temporal da unidade produtiva e visa ao aumento de retorno econômico, à sustentabilidade e à minimização do efeito ao ambiente” (BRASIL, 2012) um sistema de gestão que leva em conta a variabilidade espacial do campo com o objetivo de obter um resultado sustentável social, econômico e ambiental, que passou por uma atualização ainda em vigor (BRASIL, 2017) .

Em 1929, num boletim do campo experimental de Illinois, Linsley e Bauer recomendavam ao produtor desenhar um mapa com testes de acidez em solos amostrados em grade para aplicação de calcário. Segundo a literatura, esse é o mais antigo registro de que a variabilidade era conhecida e que já se recomendava ao agricultor levá-la em conta (LINSLEY e BAUER, 1929). Stafford (2000), porém, lembra que os agricultores há séculos considera a variabilidade espacial na implantação da lavoura.

De fato, considerar a variabilidade é reconhecer que o campo não é uniforme e nela há aptidões agrônômicas diferentes, mesmo em uma propriedade cuja dimensão não seja extensa. Agricultores mais atentos reconhecem essas áreas, que podem se mostrar manchadas por ter melhor capacidade de drenagem, ou por ter maior quantidade de matéria orgânica, entre outros fatores, fazendo com que opte por implantar de pomares a hortas, buscando aproveitar o melhor dos atributos agrônômico (BASSOI, 2014).

Na década de 80 era disseminado o uso da eletrônica embarcada em veículos influenciando o desenvolvimento das máquinas agrícolas. No chão de fábrica das indústrias metal-mecânica, as máquinas programáveis, veículos autoguiados e robôs industriais estabeleciam um novo processo de fabricação mais flexível e eficiente. Softwares de desenhos em computadores (*Computer-Aided Designe - CAD*), assim como desenhos de mapas e visualização de imagens de satélite estavam sendo desenvolvidos para terminais gráficos considerados na época de alto desempenho (DA SILVA, 2020).

O primeiro sistema global de navegação por satélite (*Global Navigation Satellite Systems - GNSS*) desenvolvido pelos EUA e denominado de GPS (*Global Positioning System*) iniciou as primeiras operações em 1978, e considerado operacional em 1995. A disponibilização de sinal de satélites GPS, viabilizou a instalação de receptores em colhedoras, possibilitando armazenar dados de produção instantânea associada à coordenada geográfica. Em 1996, surge no mercado colhedoras com capacidade de mapeamento da produção, gerando o boom da Agricultura de Precisão no mundo, tornando possível a prática de mapeamento e aplicação de insumos à taxa variada por meio de máquinas (WHELAN E TAYLOR, 2013).

O setor acadêmico inicia atividades em Agricultura de Precisão, em 1996, com o primeiro simpósio em Agricultura de Precisão realizado na ESALQ (BALASTREIRE, 2000).

Para a grande maioria, o argumento de realizar a operação de forma mais precisa, ou seja, com menor erro parece ser suficiente para iniciar a adoção da AP. De forma didática há dois tipos de erros. O antrópico e o natural. O erro antrópico pode ser corrigido na grande maioria das situações por meio de uso e escolha correta das máquinas. A eletrônica embarcada pode auxiliar para que as operações sejam menos dependentes da habilidade e experiência do operador, mantendo a máquina dentro dos parâmetros de operação aceitável. Entretanto, o retorno econômico nesse caso é obtido somente se a operação de forma manual apresentar um erro significativo (SCARLETT, 2001).

Para erros maiores a correção causará maior economia ou maior impacto econômico. Para erros não antrópicos ou naturais o argumento mais comum é a intensidade da diferença. Se uma propriedade apresenta diferença de produção de duas a dez toneladas por hectare e a aplicação de insumo foi uniforme, então, é fácil entender que em algum ponto está-se aplicando excesso de insumo, gerando desperdício e, em outro uma quantidade insuficiente perdendo a oportunidade de se obter uma produção maior. Quanto maior a diferença, maior a oportunidade de se obter retorno econômico ao se tratar adequadamente as características que as diferenciam. Por outro lado, se um sistema de produção apresentar diferença pouco significativa, o retorno econômico seguramente será insignificante ou até negativo (DE MIRANDA, et al., 2017).

É por esse motivo que a AP pode ser entendida como uma forma de gestão da lavoura que leva em conta a variabilidade espacial. Recomenda-se somente é se houver potencial de retorno econômico e ambiental e nesse caso é necessário que haja a variabilidade espacial. Apesar da variabilidade espacial ser intrínseca da espacial. Apesar da variabilidade espacial ser intrínseca da as situações o retorno econômico seja obtido, pois, em tese, a variação pode ser suficientemente reduzida para que a lavoura seja considerada próxima do uniforme (MCBRATNEY, et al., 2005).

Oliveira, Bernardi e Rabello (2011) nessa publicação, apoiado por medidas de condutividade elétrica, apresenta índice de oportunidade para apontar o potencial de retorno econômico da AP. Além da intensidade, se a causa da variabilidade não permitir uma gestão apropriada, o retorno econômico também não será alcançado. Por exemplo, um processo que ainda não está muito bem resolvido comercialmente é o controle de plantas daninhas, pois para esse fator a tecnologia mais eficiente ainda é o manual. Ou seja, o processo de identificação e aplicação realizado manualmente.

As metodologias de detecção de plantas daninhas em campo ainda dependem do desenvolvimento de sensores que identificariam rápido o suficiente para controlar a aplicação de herbicida de forma localizada em tempo real. Outro exemplo a textura do solo - mesmo encontrando a variabilidade, não há meios de corrigir, mas há meio de buscar proveito dessa variabilidade (WEISS, et al., 2020).

O retorno econômico, portanto, depende de cada lavoura e dos processos de cada produtor. O primeiro passo é identificar a variabilidade espacial da lavoura. As formas mais comuns aplicadas no Brasil parecem ser por meio de amostragem em grade realizada por empresas de serviço e mapas de produtividade (ou de colheita) obtidos por meio de máquinas. Em qualquer uma das situações, há necessidade de um investimento e, na maioria dos casos os custos não são considerados baixos (WHELAN E TAYLOR, 2013).

Em caso de amostragem de solo, a qualidade do mapa depende do processo de retirada da amostra e da qualidade da análise, pois esse método é o convencional, mas depende também da quantidade de amostras. A pergunta mais comum nesse caso é o número de amostragem ou a distância entre as amostras, pois esse fator determina o custo do processo. Muitos realizam uma amostra a cada cinco hectares, os mais refinados alcançam uma amostra a cada hectare, porém esse refinamento pode não ser suficiente, pois há possibilidade de que haja variações entre as leituras, as quais deveriam ser consideradas para aplicação de insumo à taxa variada. Para cada local há um número recomendável de amostras (BASSOI, 2014).

A amostragem em grade na quantidade realizada atualmente não é suficiente para obter um mapa com qualidade para aplicação de insumos como o de fertilizantes, muito embora, é preferível ter uma amostra a cada cinco hectares do que a cada vinte hectares e assim por diante (BASSOI, 2014).

O refinamento poderia chegar à dimensão do domínio de absorção das raízes, porém, apesar de alguns defensores dessa resolução, para muitos não faz sentido chegar a tal refinamento se a máquina de aplicação de insumos não consegue atuar com tal resolução. Nesse sentido, se uma máquina tem largura de aplicação de seis metros e o tempo de resposta do sistema responde apenas em seis metros, então essa distância seria considerada a menor, porém para aplicação, por exemplo, de herbicida, poderia ser menor se o processo de identificação da planta alvo e o método de aplicação tiver capacidade de atuar planta a planta (COELHO, et. al., 2009).

Evidentemente não é possível assegurar uma aplicação nessa resolução se a amostragem foi realizada a cada cinco hectares e esse fato fundamenta os críticos da AP, porém, há formas de atenuar a falta de dados. Mapas de produtividade, mapas de condutividade elétrica aparente do solo, imagens aéreas (sensoriamentos remotos e próximos), topografia (paisagem) com pedologia refinada pode chegar a uma continuidade de leitura ou de dados a cada três metros com custo razoável, e essas medidas indicam indiretamente como ocorre a variabilidade da lavoura. Essas indicações indiretas são medidas que auxiliam e orientam uma amostragem mais estratégica, reduzindo a necessidade de um número elevado de amostras colhidas às cegas em uma distância regular em grade.

Mais do que orientar o número de amostragem, mais importante ainda é o local (coordenada geográfica) do ponto de amostragem e como é o formato da fronteira entre as áreas com características distintas. Nessas condições, a interpolação como krigagem encontra as condições matematicamente corretas para o seu emprego (CHERUBIN, et al., 2016).

O termo “precisão”, vem do inglês “*precision agriculture*” - foi criado nos EUA. Na Europa, o emprego do termo “*precision farming*” é mais amplo, talvez devido ao termo “farming” contextualizar ou fechar o escopo nas atividades relacionadas à produção da propriedade agrícola, ou seja, gestão da propriedade (CIRANI e MORAES, 2010).

No Brasil, houve quem utilizasse o termo em tudo que se referia à atividade realizada com maior precisão por meio de sistemas eletrônicos. Essa forma de uso realçou a necessidade de maior precisão nas tarefas agrícolas como a necessidade de máquinas e sistemas de análise mais precisos, misturando todos os conceitos de medida e atuação agrícola (CIRANI e MORAES, 2010).

Uma máquina precisa, ou seja, com sistema de distribuição uniforme e regular, com mínimo de variação dentro das especificações de ajuste, é uma máquina convencional, que realiza uma operação precisa e com erro dentro de uma faixa tolerável, porém, não é uma máquina que se destina à Agricultura de Precisão, pois não apoia na gestão da variabilidade espacial da lavoura e nem aplica insumos à taxa variada (WEISS, et al., 2020).

Portanto, definitivamente uma máquina precisa não está diretamente relacionada a uma máquina para Agricultura de Precisão. Porém, uma máquina para a Agricultura de Precisão deve ser precisa na sua atuação, assim como deve ser para o uso convencional. O mesmo pode ser empregado na análise de solo (WEISS, et al., 2020).

A análise do solo pode ser precisa, mas se não obtiver um mapa que represente a variabilidade e está presente a variação da produtividade, não pode ser considerada uma atividade destinada à Agricultura de Precisão, cuja técnica suscita questionamento quanto à localidade da amostra. Se em uma propriedade, duas amostras de locais diferentes apresentam uma recomendação diferenciada que impacta economicamente, então a aplicação de fertilizante (MAESTRINI e BASSO, 2018).

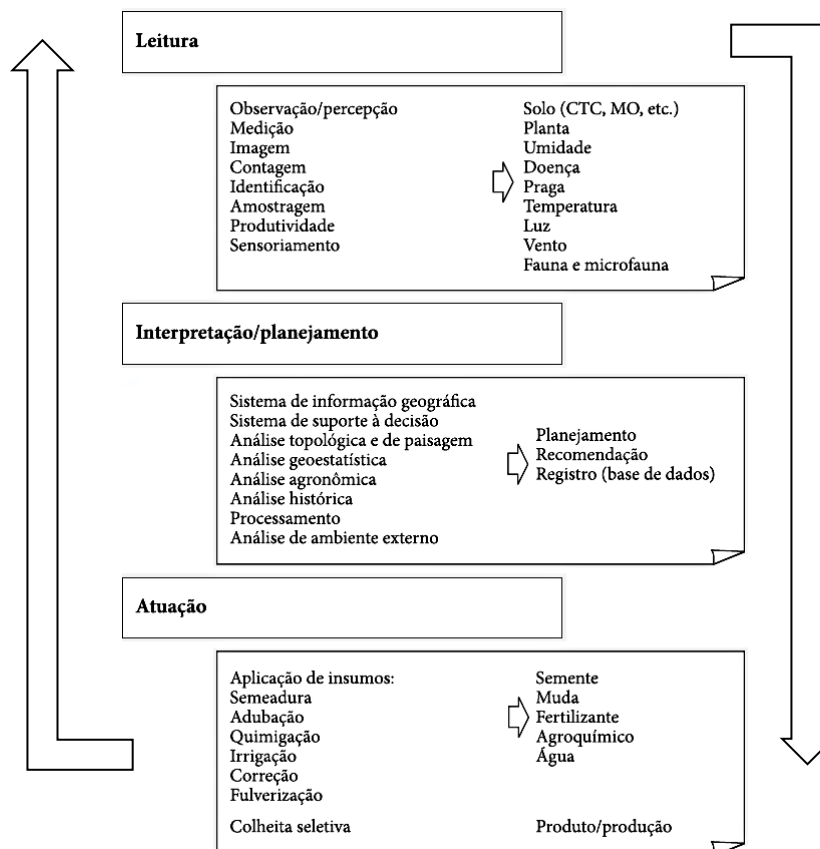


Figura 9. Ciclo da agricultura de precisão em três etapas (MOLIN et al., 2015).

Sistemas de captação e tratamento de imagens têm atraído muita atenção, métodos empíricos têm dominado o seu uso, porém, deverá ainda apresentar contribuições mais significativas. O processo de análise e interpretação tem sido apoiado por ferramentas de SIG (Sistema de Informação Geográfica) e de geoestatística. Os SIG são parte importante para leitura de arquivos e as indústrias de máquinas buscam fornecer suporte e apoiar a interpretação dos dados. Além dos SIG comerciais, há livres como o QGIS (<http://qgisbrasil.org/>), Mantido por uma comunidade de voluntários (MOLIN et al., 2015).

2.3.2. Sensoriamento remoto aplicado na cana-de-açúcar

O sensoriamento remoto tem sido amplamente utilizado para a agricultura de precisão da cana-de-açúcar desde o final dos anos 1970. (BAUER et al, 1973. MORA et al. 2017). A série Landsat de satélite de observação da Terra é indiscutivelmente a fonte mais comum de dados de sensoriamento remoto usados para aplicações de cana-de-açúcar. Há exemplos de uso da Landsat no Brasil, Austrália, África do Sul e Tailândia. O satélite SPOT (*Satellite Pour l'Observation de la Terre*), com uma resolução média, também foi usado principalmente na Austrália, África do Sul e na Ilha da Reunião (RAHMAN et al, 2018). O satélite MODIS (Espectro Radiômetro de Imagem de Resolução Moderada), com uma resolução grosseira (250-1000 m) foi citado para classificação de cana-de-açúcar no Brasil e em Moçambique, mas com menos sucesso (confusão com pasto) (ABDEL-RAHMAN & AHME, 2008).

Duveiller et. al. (2013) utilizaram a Fração da Radiação Fotosinteticamente Ativa Absorvida (FPAR) calculada a partir dos dados SPOT *Vegetation* para estimar a produtividade das culturas no Estado de São Paulo, Brasil. Alguns estudos também investigaram o uso de dados SAR (*Synthetic Aperture Radar*) para mapeamento de monitoramento de lavouras de cana-de-açúcar. Em seu estudo, Johnson, A. & Kinsey-Henderson (1997), usaram dados de radar SPOT e ERS-1 para mapear o uso da terra em uma grande área de cana-de-açúcar na Austrália.

Os dados SAR são algumas vezes mencionados como uma alternativa aos dados ópticos quando a cobertura de nuvens é um problema, especialmente durante as estações chuvosas. Em um estudo mais sistemático, Baghdadi (2009), avaliaram TerraSAR-X, ASAR (ENVISAT) e PALSAR (ALOS) quanto ao seu potencial para monitorar plantações de cana-de-açúcar na Ilha da Reunião usando abordagens multi-temporais. Eles relacionaram o coeficiente de

retroespalhamento SAR (σ_0) ao NDVI (índice de vegetação de diferença normalizado calculado a partir de dados SPOT), a altura das plantas e a colheita.

Os autores mencionados descobriram que 1) os campos colhidos podem ser facilmente detectados, 2) a altura da planta está melhor relacionada com o alto ângulo de incidência do radar, 3) os dados de polarização cruzada (HV ou VH) são ligeiramente melhores do que os dados co-polarizados (HH, VV) para caracterizar o estado da plantação (cultivado, colhido, maduro), 4) a banda X é possivelmente menos sensível à rugosidade do solo do que a banda L- (PALSAR) e a banda C (ERS). Além deste estudo, poucos pesquisadores investigaram a utilidade dos dados SAR para aplicação em cana-de-açúcar.

Moran (1997) e Abdel-Rahman (2008) apresentaram uma visão geral, identificando uma série de aplicações no manejo da cana-de-açúcar para as quais o sensoriamento remoto tem sido usado com relativo sucesso (Tabela 2).

Tabela 2 - Síntese de aplicações de SR em *cana-de-açúcar*

Aplicações	
1. classificação dos canaviais	7. variabilidade do solo
2. mapeamento de extensão aérea	8. monitorar a variabilidade do solo e das culturas
3. identificação da faixa etária térmica	9. Identificando doenças
4. Separação varietal	10. identificando as causas da variabilidade
5. generalizando medidas de ponto	11. Modelo digital de elevação
6. previsão de rendimento da colheita	12. Gerenciamento de produção em tempo crítico

2.3.3. Característica da produção de cana-de-açúcar relevantes ao emprego de sensoriamento remoto

A luz solar incide sobre a superfície da terra e provoca interações com todos os diferentes tipos de superfícies, que são identificados como alvos, sejam eles objetos construídos em áreas urbanas, alvos naturais como rios e florestas, e alvos implantados como culturas agrícolas. Quando a luz atinge os alvos, ela interage refletindo, absorvendo ou transmitindo parte da energia. Na produção de cana-de-açúcar o processo ocorre da mesma maneira e a refletância espectral da cobertura do dossel é intrínseca da combinação entre a refletância da planta e a proporção de cobertura do solo (GUYOT, 1990).

A cana-de-açúcar sofre interferência na resposta espectral pela quantidade e composição de nutrientes aplicados, que afetam a planta diretamente na capacidade de absorção de luz (KUMAR et al. 2003, MUTANGA et al. 2004, GALVÃO et al. 2005).

Os pigmentos de clorofila, que fornecem a tonalidade de verde na planta, são os grandes responsáveis por absorção na faixa do vermelho e de alta refletância no infravermelho. Eles

respondem com alterações na folha pela clorofila *a* e *b*, caroteno, xantofila e antocianinas (GUYOT, 1990; de BOER 1993; VAN DER MEER et al. 2003), que por sua vez são a parte fisiológica relacionada ao desenvolvimento da planta (MUCHOW et al. 1996; LUTHER & CARROLL 1999; ZHAO et al. 2005; ISA et al. 2006).

Um nutriente tem forte impacto na reposta espectral, da mesma forma que a deficiência de nitrogênio afeta o desenvolvimento da planta, modificando a tonalidade de verde da clorofila, alterando a refletância espectral (GUYOT 1990, ZHAO et al. 2005). A quantidade de água contida na folha altera a capacidade de absorção e refletância na folha e influencia diretamente na resposta espectral (PONZONI et al. 2015).

A relação entre parâmetros físicos da vegetação e áreas de produção agrícola foi aplicada para analisar o comportamento de espectral com aplicação de índices de área foliar, análise de biomassa e crescimento da vegetação e cobertura do solo (ASRAR et al. 1984).

Fatores de relação entre a radiação eletromagnética e a fotossíntese das folhas identificaram a influência da resposta espectral do dossel. A resposta do dossel está condicionada à espécie da planta, tamanho, distribuição e o ângulo arquitetônico das folhas, maturação e a senescência das folhas, efeitos de stress, condição nutricional, percentual de cobertura do solo (LAI) e o tipo de solo (GOEL & STREBEL 1984; Al-ABBAS et al. 1974; MASONI et al. 1994; HUETE et al., 1985).

Vários autores discutiram a interação da luz com a cana-de-açúcar e a reposta da planta, utilizando o satélite Landsat 7 ETM+, quando foi analisado o comportamento espectral da cana-de-açúcar e a variação da resposta espectral entre as bandas. O comportamento da cana apresentou variação entre as bandas espectrais e foi possível identificar a variação do comportamento espectral entre quatro variedades de espécie da planta (FORTES & DEMATTÊ, 2006).

A resposta espectral da cana-de-açúcar depende de fatores que são predeterminantes: composição química da folha, arquitetura do dossel, parâmetros agrônômicos, geometria dos dados adquiridos, condição atmosférica (FORTES & DEMATTÊ, 2006). Há trabalhos que mapearam resposta espectral e a interação com a luz usando espectro radiômetro de campo (SIMÕES et al. 2005; SINGELS et al. 2005; SMIT & SINGELS 2006; TEJERAS et al. 2007).

As folhas da cana-de-açúcar têm estrutura diferente de acordo com cada variedade. As variações na arquitetura da folha não têm grandes variações como em outras produções agrícolas, mas a estrutura do dossel formado pela característica arquitetura da folha apresenta variações e produz uma maior refletância para o planófilo (folhagem média ereta) do que as

plantas de cana-de-açúcar eritrofilas (folhagem ereta) (GALVÃO et al. 2005; FORTES & DEMATTÊ, 2006).

A quantidade de interação da luz com as folhas irá variar de acordo com a variedade da planta, que tem estrutura do colmo e quantidade de folhas subjacentes com arquitetura e quantidade distintas. A variação da estrutura da foliar e no espaçamento dos entre nós configura a capacidade de entrada de luz até as folhas mais distantes do topo do dossel. (TEJERA et al., 2007).

Segundo Raji et al. (1999), quanto maior a área de superfície verde, maior capacidade de fotossíntese. Porém, foi identificado que quanto maior o IAF, diminui a capacidade da planta na interceptação de luz nas folhas subjacentes (TEJERA et al., 2007), (RODRIGUES LIMA et al., 2005).

Para maior compreensão do comportamento da sobre a resposta espectral em cana-de-açúcar é necessário maior estudo e descrição dos parâmetros agrícolas em sua produção. Assim, cabe incluir no modelo de análise o planejamento da sistematização (planta baixa da produção), o sistema de conservação de solo, a direção da linha de plantio, o comportamento topográfico, o período de plantio, o sistema de irrigação e a forma de aplicação de nutrientes. Neste trabalho será abordado a inclusão de novas variáveis específicas para a cana-de-açúcar.

São parâmetros agrônômicos as condições geográficas, físicas e geomorfológicas, de conservação de solo, a sistematização e processo de colheita, o manejo de irrigação/fertirrigação, o estágio de crescimento e a direção de plantio na produção de cana-de-açúcar. Serão abordadas nesse trabalho com maiores detalhes as condições de produção da cana-de-açúcar segundo os efeitos sobre a resposta espectral do dossel, que por sua vez reflete a forma de operação e sistematização do canavial (BHERING, 2003).

2.3.4. Classificação de área de cana-de-açúcar e abrangência da produção

A tecnologia do Sensoriamento Remoto (SR) tem o potencial de melhorar significativamente a qualidade (disponibilidade, pontualidade e precisão) das informações sobre a produção agrícola mundial (BAUER, 1975). O LACIE (*Large Area Crop Inventory Experiment*) desenvolveu técnicas para identificar campos de treinamento de trigo e não-trigo diretamente das imagens do LANDSAT MSS (MacDONALD e HALL, 1977).

No Brasil há o projeto CANASAT, pioneiro no monitoramento das áreas de colheita de cana por sensoriamento remoto. Foi desenvolvido pelo INPE (Instituto Nacional de Pesquisas Espaciais), em parceria com a ÚNICA (União das Indústrias de Cana-de-Açúcar) e o CEPEA-

USP (CEPEA - Centro de Estudos Avançados em Economia Aplicada da Universidade de São Paulo) (Rudorff et al., 2010). Inicialmente, o mapeamento foi realizado apenas no estado de São Paulo (Rudorff et al., 2005), no entanto, desde 2005, ele foi estendido para os outros cinco estados da região Centro-Sul do Brasil (Rudorff e Sugawara, 2007). Esses seis estados são responsáveis por 72,7% da produção de cana-de-açúcar no Brasil.

Com o objetivo de atender a uma demanda sustentável, o projeto trouxe a luz o controle de todas as áreas de colheita de cana, com os satélites LANDSAT e CBERS, através de observações de áreas de colheita com e sem procedimento de queima. A queimada era uma prática do setor sucroalcooleiro, banida em 2012. O CANASAT monitorou de 2003 até 2014 todas as regiões de produção de cana no Brasil. O projeto serviu de base para política do etanol verde e sequestro e carbono, além de fornecer grande suporte para usinas (Rudorff et al., 2010).

Outro projeto que monitora as áreas de produção agrícola no Brasil é o Mapa Biomas, que contempla não somente o mapeamento da cana, mas toda a cobertura do solo no país. Com uma gama muito grande de dados e estatísticas, o Mapa Biomas é bem completo como suporte de dados para estudos e pesquisas (SOUZA et al. 2020).

Aplicações de separação de alvos por classificação de imagens por satélite têm início em nos anos 70 com advento do Landsat das imagens do sensor MSS. O sensor MSS foi utilizado na separação para classificação supervisionada e não supervisionada, separando soja, milho e outras culturas. Com metodologias de classificação por máxima verossimilhança e análise de matriz de acurácia dos resultados, o Landsat apresentou resultados com precisão 84.9% para milho, com erro de 3.7% .(BAUER et al. 1979).

Estudos com Landsat *Thematic Mapper* (TM) sobre assinatura espectral em cana-de-açúcar na Austrália identificaram que as bandas 1 (Azul), 2 (Verde) e 3 (Vermelho) respondem de forma estreita entre as faixas, permitindo separar melhor a cultura do que a condição produtiva da cultura. (LEE-LOVICK e KIRCHNER, 1991)

Diferentes culturas foram discriminadas, dentre elas a cana-de-açúcar de café e frutíferas cítricas, usando imagem Landsat com acurácia na classificação maior que 0.95% (TARDIN et al. 1992). Usando as imagens SPOT e EAR-1 foram analisadas regiões de produção de cana na Austrália, o que validou a possibilidade de monitoramento da cana pelos dados dos sensores. A combinação da e imagens SPOT e ERS-1 permitiu concluir que a coleta simultânea é adequada para avaliação acurada da cobertura do solo com produção de cana (JOHNSON E KINSEY-HENDERSON, 1997).

A identificação da cana-de-açúcar pelo Landsat TM estimou o total de produção em uma região de produção na África do sul. Os resultados alcançados tiveram uma variação de 5% de imprecisão na área total mensurada em 46 fazendas. (NARCISO E SCHMIDT, 1999)

Na Austrália, Markley et al. (2003) usaram imagens do SPOT 5 e Landsat 7 ETM+ para calcular a área de produção de cana-de-açúcar. A pesquisa demonstrou, por métodos de detecção, que o cálculo por sensoriamento remoto teve uma diferença de apenas 2% de área em relação a área calculada pelo GPS da colhedora e pelo GPS de mão.

Bégué et. al. (2004) relataram que os campos de cana-de-açúcar colhidos e lavrados poderiam ser facilmente mapeados com precisão de >0,90%.

O sensor MODIS tem uma capacidade de resolução temporal e quantidade de dados com abundância para monitoramento agrícola, através da aplicação do sensor utilizando os dados de índice de vegetação. Pelo modo de classificação não supervisionado diferenciou-se cana de outras culturas e áreas naturais, tais como soja, florestas, amendoim e área urbana. Contudo, a maior dificuldade foi diferenciar cana de pasto, que apresentou comportamento espectral similar. Para minimizar os efeitos da confusão podem ser usadas outras imagens de maior resolução espacial, ou utilizar dados auxiliares como polígonos para extrair segundo uma máscara (XAVIER et al. 2006).

Existem análises que propõem conciliar o uso de sensoriamento remoto com metodologia de identificação de produção de cana em pequena escala, e se fazer levantamento de inventário de toda área de disponível em uma safra. (AFRICA BY GERS, 2004). Masood e Javed (2004) relatam um estudo feito no Paquistão usando um modelo de previsão de área de produção de cana com até dois meses antes da colheita.

Trabalhos feitos com espectrômetros de campo descreveram separação espectral de cana e de outros alvos, identificando a proporção de cobertura da superfície, o que separou as misturas espectrais do pixel das folhas de solo e outros elementos que interferem na composição do pixel na área de cana-de-açúcar. A pesquisa usou técnicas de mistura espectral com dois instrumentos espectrômetros de coleta em campo. Seus resultados apresentaram diferenciação da resposta entre o topo do dossel, folhas e o tipo de variedade cultivada. Assim, por meio dos dados de campo ficaram estabelecido os membros finais (*endmembers*) para folhas, topo do dossel, e variedade, com precisão das estimativas. (TULIP E WILKINS, 2005)

O estágio fonológico da cana define a idade de crescimento da cultura, o que está diretamente relacionado ao período térmico da planta, ou seja, conforme a idade da muda aumenta a condição de temperatura da planta. Esse processo determina as janelas de período térmico da planta que tem uma temperatura de base (ABDEL-RAHMAN AND AHMED 2008).

Por meio do uso de sistema de videografia multiespectral, Schmidt et al. (2000) relataram que foi possível identificar as faixas de estágio de crescimento da cana. Para Gers (2003b, 2004) o estágio de crescimento da cana pode se distinguidas usando o sensor Landsat ETM+.

No entanto, existe a necessidade de analisar os dados meteorológicos para melhor compreensão das fases de estágio de crescimento da cana, assim como os limites de cada sensor segundo o tipo de irrigação, depleção de água no solo, correção atmosférica das imagens e tipo de fertilizantes. (GERS 2004).

2.3.5. Identificação varietal

As variedades de cana-de-açúcar e o processo de identificação, são um dos principais pilares para a previsão de safra, manejo da produção, controle de royalty, distribuição geográfica e avaliação de riscos associados para diferentes regiões de produção do Brasil. O processo de produção de novas espécies tem aumentado, e a introdução de novas variedades e a diversificação de espécies no canavial fica a cada ano mais intenso.

O comportamento de cada variedade é direcionado para o plantio de acordo com os parâmetros de ambiente de produção (processo de mapeamento e classificação de locais com características físicas homogêneas). No entanto, a distribuição em milhares de hectares torna o manejo extremamente complexo. O erro de mensuração em apenas uma variável, a exemplo o período para a colheita de uma variedade, pode resultar em perda de toneladas de açúcar por hectare. Por isso a identificação e o monitoramento do comportamento espectral de cada variedade permitirão definir o melhor momento para se extrair o máximo de açúcar e etanol.

Foi aplicado sensoriamento remoto para identificar tipos de variedade de cana-de-açúcar com dados multiespectrais no Brasil (FORTES E DEMATTE 2006; GALVÃO ET AL., 2005, 2006) na África do Sul (GERS 2004) e com dados hiperespectrais nos EUA (JOHNSON et al. 2005) e Austrália (APAN et al. 2004b).

Fortes e Dematte (2006) utilizaram a análise de bandas espectrais e índices de vegetação para discriminarem a as variedades de cana-de-açúcar (Figura 9). As imagens do Landsat 7 ETM+ passaram pelo processo de correção atmosférica do modelo 5S (Modelo de Simulação do Sinal de Satélite no Espectro Solar) para transformar os dados de DN (Níveis de cinza) para refletância e gerar análise das bandas e dos índices (TANRE´ et al. 1990). Com a elaboração de equações, eles desenvolveram a identificação e separação de quatro variedades. Para tanto, foi relacionado bandas espectrais separadas e índices de vegetação extraídos do sensor Landsat

ETM+, que resultou uma certeza de 93.6%. Fortes e Dematte (2006) não obtiveram resultado de separação de variedades usando sensor CCD do CBERS-2, SPOT-5, NOAA/AVHRR e TERRA/ASTER.

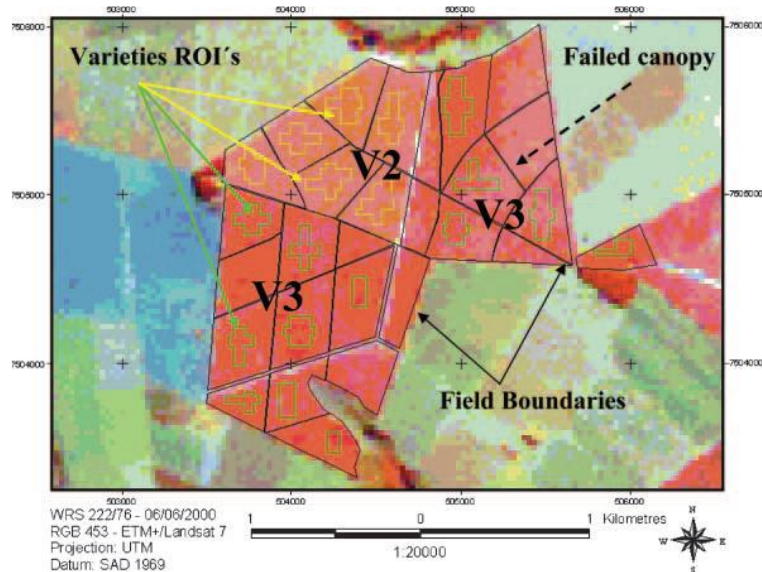


Figura 10 - Exemplos de regiões de interesse (ROIs) para coleta de dados espectrais das variedades V2 (RB855536) e (RB855113). Fonte: Fortes e Demattê, 2006.

Em pesquisa realizada na Austrália, foi utilizado o sensor do EO-1 Hyperion para tentar discriminar 5 variedades de cana-de-açúcar. A metodologia utilizou como procedimento a conversão dos dados de radiância em refletância de superfície, realizou cálculos de proporção conjuntamente com extração de índices de vegetação potencialmente sensíveis a clorofila e água na folha. Foi possível identificar as variedades separadamente as amostras com uma precisão de 97% para 5 variedades e para 8 variedades com 74%. Contudo, a classificação da imagem inteira a precisão caiu para 46%, que foi relacionado ao grande número de classes e variações ocasionadas pelo manejo da cultura (APAN, et al. 2004b).

Os sensores hiperespectrais têm uma capacidade de detalhar informações do alvo muito além dos outros modelos de sensores. O princípio foi demonstrado por Johnson et al. (2005), que conseguiram distinguir sete variedades de cana-de-açúcar cultivadas nos EUA. O trabalho coletou dados *in situ* com um hiperespectrômetro de campo em condições de luz natural, para correlação com dados dos sensores orbitais e a distinção teve sucesso.

O sensoriamento remoto com dados hiperespectrais mostrou capacidade de separar as variedades de forma mais precisa e com resultados que permite mapeamento de um espectro acima de 5 variedades, o que já representa uma realidade para aplicação. Porém, dados de

sensores espectrais ainda são muito caros e pouco explorados para o setor de produção de cana-de-açúcar. (ABDEL-RAHMAN AND AHMED, 2008)

2.4. Classificação de imagens de satélite na agricultura

Cabe discutir as diferentes formas de classificação de imagens de satélite e verificar, a partir da bibliografia consultada, os empregos mais eficazes e indicados para a agricultura.

2.4.1. Classificação orientada a objeto

A abordagem baseada em objeto permite explorar na classificação de imagem não apenas o valor digital do pixel (no domínio espectral, como a abordagem baseada em pixel faz), mas também outras características (atributos) como, por exemplo, forma, tamanho, textura, padrão, contexto, que podem ser discriminadores de objetos visualmente perceptíveis na imagem. Nesse ponto, a abordagem pode ser considerada como um passo significativo para superar as limitações reconhecidas da classificação tradicional baseada em pixels.

Ao contrário dos classificadores tradicionais, que são amplamente acessíveis em muitos pacotes de software, o software de análise de imagens orientado a objetos ainda é uma solução única. O procedimento chave no fluxo de processamento da análise orientada a objetos *raster* é a segmentação - a tecnologia patenteada que permite extrair as estruturas homogêneas de objetos em diferentes níveis de resolução (escala espacial) aplicando discriminadores de objetos relacionados espectrais e espaciais relevantes (BLASCHKE, 2000).

O pacote *eCognition* (atualmente *Definiens*) foi o primeiro software geral de análise de imagens orientado a objetos no mercado (TZOTSOS & ARGIALAS, 2008). A questão chave da segmentação é o critério de heterogeneidade que considera como características primárias a cor e a forma do objeto. O parâmetro de escala é o critério de parada para o processo de otimização.

Os objetos resultantes podem ser caracterizados por diferentes conjuntos de recursos definidos no domínio espectral e espacial. Entre camadas sequenciais de resultados de segmentação de resolução diferente, uma rede hierárquica de objetos de imagem é construída (AKÇAY & AKSOY, 2008).

O uso de informações de forma, textura, vizinhança e localização junto às informações espectrais é benéfico para a classificação da agricultura irrigada. O pressuposto subjacente é que a aplicação de irrigação tem um efeito positivo no crescimento da cultura em todo o campo, seguindo as bordas do campo, o que é detectável em uma abordagem baseada em objetos. O tipo de sistema agrícola também foi mapeado por Vogels (2019), distinguindo a agricultura familiar e a moderna agricultura em grande escala. A agricultura irrigada foi mapeada com uma precisão geral de 94% e um coeficiente Kappa de 0,85. As precisões do produtor e do usuário foram em média 90,6% e 84,2%, respectivamente.

Forster et. al. (2010) realizaram estudo com classificação supervisionada que revelou uma precisão geral de 84% com um coeficiente κ de 0,77 para a segmentação vetorial por campo em comparação com uma precisão geral de 56–60% e um coeficiente κ de 0,37–0,42 para abordagens baseadas em objetos. A segmentação vetorial por campo foi, portanto, superior e usada para classificação LCLU (*Land Cover, Land Use*) em nível comunitário. A precisão geral foi de 83% e o coeficiente κ de 0,7. Na agricultura diversificada, a segmentação e classificação de vetores por campo alcançaram resultados de classificação mais elevados. (

Em relação à análise de dados multitemporal, estudos empregaram uma abordagem orientada a objetos para definir objetos, campos agrícolas, com dados cadastrais. Esta abordagem foi avaliada em comparação com uma abordagem baseada em pixels. Os resultados indicam que uma imagem ETM + SLC-off pode ser classificada com melhor que 85% de precisão geral sem preenchimento de lacunas (LONG et. al., 2013).

No que se refere a estudos sobre treinamento automaticamente rotulado (com uma precisão geral média de 93,76%) foi utilizada a operação Canny e bacia hidrográfica como algoritmo de segmentação, sendo que o limite do campo agrícola foi delineado usando R2U-Net treinado e métodos de conexão de limite (a média precisão geral de 89,28%). O método baseado em bacia hidrográfica Canny foi escolhido para coletar o conjunto de dados de treinamento, mas o conjunto de dados de treinamento não foi usado para obter os resultados finais do limite da área de estudo (ZHANG et. Al., 2021).

Sobre a classificação supervisionada baseada em objeto, foi descoberta e está experimentando avanços rápidos por meio do desenvolvimento da técnica *fuzzy*, aplicado na estrutura do objeto. (JOHANSEN, 2021).

Além disso, a resolução espacial se correlaciona com a escala de segmentação ideal e área de estudo, e *Random Forest* (RF) mostra o melhor desempenho na classificação baseada em objetos (SOTHE, et. Al., 2017). Para Formaggio & Sanches (2017), a precisão baseada em área método de avaliação pode obter um desempenho de classificação estável e indica uma forte

correlação entre a precisão e o tamanho do conjunto de treinamento, enquanto a precisão do método baseado em pontos provavelmente será instável devido a objetos mistos.

A precisão geral se beneficia de uma resolução espacial mais alta de imagens (por exemplo de captura drone) e também com número de classes identificadas. Mais de 95,6% dos estudos envolvem área inferior a 300ha, sendo a resolução espacial de imagens é predominantemente entre 0 e 2 m. Alguns métodos realizam classificação avançada de imagem baseada em objeto supervisionada. Por exemplo, *deep learning* e técnicas fuzzy tipo 2 pode melhorar ainda mais a precisão da classificação, (MA, et. Al., 2017).

As áreas de cana-de-açúcar foram mapeadas no Brasil, com a demanda de mapeamento em larga escala, utilizou métodos para melhor identificar áreas de cana em relação as outras culturas, principalmente áreas prontas para colher. Com dados do satélite LANDSAT 5 TM, aplicou métodos de OBIA, classificação por mineração de dados. Resultados de classificação apresentaram altos níveis de exatidão, com a Precisão Global e a Coeficientes Kappa atingindo 93,99% e 0,87, respectivamente. Essas medidas de alta precisão foram obtidos em um conjunto de amostra de 500 pixels não previamente usado durante o desenvolvimento do modelo (DOS SANTOS LUCIANO, 2019).

É importante estar familiarizado com as especificidades da fenologia das culturas dinâmica ao longo de seus ciclos. Vieira et al. (2012) foram capazes de provar a possibilidade de integrar OBIA e DM para emular o conhecimento de um especialista humano, uma vez que a Árvore de Decisão obtida em um sistema automatizado a moda conseguiu distinguir a cana-de-açúcar das safras de verão, pastagens e florestas, usando atributos espectrais e texturais. A Árvore de Decisão permite a exploração de uma série temporal de imagens, levando em consideração as características da dinâmica temporal de as fenologias das culturas estudadas.

O método GLCM (*Gray Level Co-occurrence Matrix*) foi capaz de encontrar atributos de textura (por exemplo homogeneidade) que possibilitou a separação esperada dessas classes. Algoritmos convencionais baseados apenas em atributos estatísticos de pixels individuais não são capazes de usar esse recurso e, portanto, provavelmente não tem sido capaz de realizar a separação (KIM, et. al., 2011).

O potencial de mineração de dados e da análise de Imagens baseada em objetos tem contribuído de forma relevante para a automação de processos na classificação de imagens de sensoriamento remoto aplicadas ao mapeamento agrícola (PENA, et al. 2015).

Na segmentação multi-resolução a geração de objetos está sujeita ao critério de heterogeneidade, o que pode ser ajustado selecionando o parâmetro de escala, os pesos das

bandas espectrais, o fator de forma e o fator de compactação. Um ajuste na escala parâmetro, por exemplo, influencia diretamente o tamanho dos segmentos gerados (DEFINIENS, 2006).

No entanto, para se desenvolver um sistema totalmente operacional, são necessárias novas pesquisas. A pesquisa deve se concentrar no impacto do momento e qualidade das imagens de satélite nos resultados da classificação. Dentro em particular a robustez do algoritmo para possíveis variações no estado fenológico da cultura e condições radiométricas/atmosféricas deve ser verificado.

Várias conclusões foram tiradas por Lei Ma (2017, p. 297) em revisão profunda de estudos com classificação orientado objeto:

- (1) Imagens de sensoriamento remoto de alta resolução espacial permanecem a fonte de dados mais frequentemente usada para objetos supervisionados classificação de imagens de cobertura da terra, e o dominante as resoluções da imagem são de 0–2 m. Além disso, devido à boa disponibilidade e acessibilidade, imagens de sensoriamento remoto da série Landsat são frequentemente empregados na classificação supervisionada baseada em objetos.
- (2) Nos estudos realizados, o tamanho da maioria das áreas de estudo é menor de 300 ha (95,6%), o que sugere a necessidade de maiores áreas de estudo em pesquisas futuras, verificando assim a aplicabilidade da técnica de classificação de imagem baseada em objeto sobre áreas mais amplas. Além disso, existe uma correlação positiva entre o tamanho das áreas de estudo e as resoluções espaciais utilizadas.
- (3) Com relação aos algoritmos de segmentação, mais estudos são inclinados a adotar a técnica de segmentação multi-escala. Existe uma correlação negativa entre a segmentação ideal escala e a resolução espacial de imagens.
- (4) Sem surpresa, imagens de sensoriamento remoto de alta resolução espacial, como as de captura drone, são vantajosas para se obter maiores precisão geral da classificação. No entanto, existem exceções. Por exemplo, as imagens do satélite *Pléiades* são principalmente aplicadas a áreas urbanas, que resultam em classificação anormalmente baixa precisão. Portanto, é necessário empregar mais imagens de sensoriamento remoto ou tipos de cobertura da terra para verificar ainda mais técnica de classificação de imagem baseada em objeto.
- (5) Existe uma forte correlação positiva entre a classificação precisões obtidas usando avaliação de precisão com base na área métodos e o tamanho das amostras de treinamento.

(6) Existe uma correlação negativa entre a classificação geral precisão e o número de classes definidas.

2.5. Classificadores *Random Forest*, *Support Vector Machine* e *Neural Networks*

Os classificadores em sensoriamento remoto compreendem mais de 20 anos de estudos e aplicações (OSISANWO, F. Y. et al. 2017). Contudo, ainda existe um vasto campo de aplicação quando se trata de investigações em alvos no terreno que precisam ser classificados e separados, mas dentro de um contexto específico do alvo (SARAVANAN, R.; SUJATHA, POTHULA, 2018).

Para avaliar o que ocorre com os classificadores, (SCHAPIRE, R., 2015) comparou a capacidade de interpretabilidade (o que o modelo de classificação interpreta) e a acurácia na classificação do alvo, por ser os classificadores SVM, RF e redes neurais considerados como “caixa preta” nos processos de análise (Figura 10). Todo o processo de classificação usando *machine learning* tem uma limitação que é a quantidade de amostras que representa da verdade sobre o terreno. (SHANG, X.; CHISHOLM, L. A., 2013).

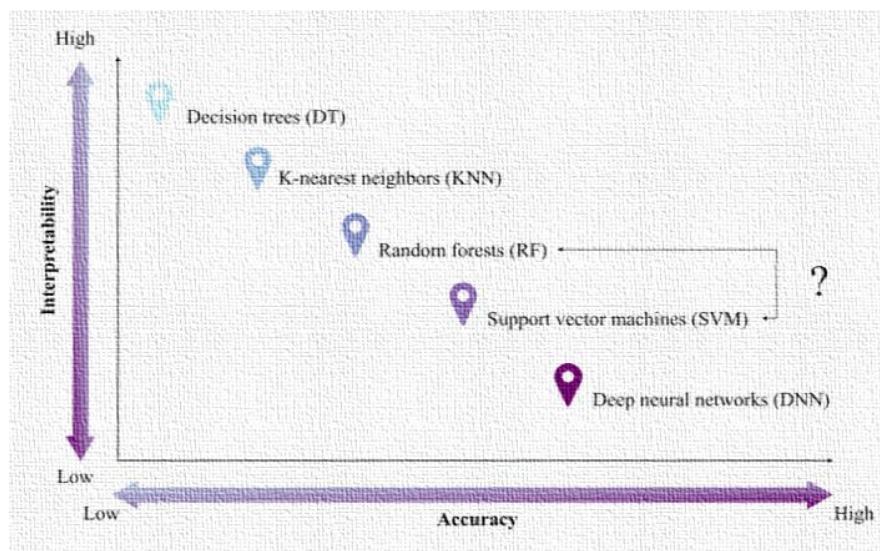


Figura 11. Interpretação e acurácia por classificação usando algoritmos de *machine learning*. Fonte: SCHAPIRE, R., 2015

Os algoritmos de classificação de imagens podem ser amplamente categorizados em abordagens supervisionadas e não supervisionadas. Classificadores supervisionados são preferidos quando quantidades suficientes de dados de treinamento são acessíveis. Os métodos paramétricos e não paramétricos são outra categorização de algoritmos de classificação com

base em suposições de distribuição de dados. Yu et al. (2019) revisaram 1651 artigos e relataram que algoritmos paramétricos supervisionados foram a técnica mais utilizada para classificação de imagens SR.

Por exemplo, o classificador de máxima verossimilhança (ML), como uma abordagem paramétrica supervisionada, foi empregada em mais de 32% dos estudos revisados. Algoritmos não paramétricos supervisionados, como SVM e classificadores de conjunto, obtiveram mais resultados precisos, mas eles foram usados com menos frequência em comparação com métodos paramétricos supervisionados (LARY, D., J. et al. 2016).

Antes da introdução da RF, o SVM estava no centro das atenções para a classificação da imagem de SR, dada a sua superioridade em relação Classificador de ML, *K-nearest neighbors* KNN (Vizinho mais próximo), redes neurais artificiais e árvore de decisão para classificação de imagens (LARY, D., J. et al. 2016).

2.5.1. Classificador Máquina de Suporte de Vetor (*Support Vector Machine*)

O algoritmo SVM, introduzido pela primeira vez no final da década de 1970 por Vapnik e seu grupo, é um dos algoritmos de aprendizado baseado em kernel mais amplamente utilizados em uma variedade de aplicações de aprendizado de máquina e, especialmente, classificação de imagens (MOUNTRAKIS, G. et al. 2011).

Em SVMs, o objetivo principal é resolver uma otimização quadrática convexa para obter uma solução globalmente ótima em teoria e, assim, superar o dilema de técnicas de aprendizado de máquina. SVM atua com dados não paramétricos para técnicas de classificações supervisionadas, que são insensíveis à distribuição de dados subjacentes. Esta é uma das vantagens dos SVMs em comparação com outras técnicas estatísticas, como ML, em que distribuição de dados deve ser conhecida com antecedência (MÚÑOZ-MARÍ, J. et al. 2010).

O SVM, em sua forma básica, é um classificador binário linear, que identifica um único limite entre duas classes. O linear O SVM assume que os dados multidimensionais são linearmente separáveis no espaço de entrada (Figura 11).




Figura 12 Hiperplano gerado pelo SVM. Fonte: MITRA, P. S. B. U., & Pal, S. K., 2004.

Em particular, os SVMs determinam um hiperplano ótimo (uma linha no caso mais simples) para separar o conjunto de dados em um número discreto de classes predefinidas usando os dados de treinamento. Para maximizar a separação ou margem, os SVMs usam uma parte da amostra de treinamento que está mais próxima do espaço de recursos para o limite de decisão ideal, atuando como suporte vetores (MITRA, P. S. B. U., & Pal, S. K., 2004).

Essas amostras são os dados mais desafiadores na classificação e podem ter um impacto direto na localização ótima do limite de decisão (MAULIK, U.; CHAKRABORTY, D. 2017). O hiperplano ótimo, ou a margem máxima, pode ser definida matematicamente e geometricamente. Refere-se a um limite de decisão que minimiza erros de classificação incorreta obtidos durante a etapa de treinamento. Vários hiperplanos são selecionados, e então o hiperplano ótimo é determinado quando a margem de separação é maximizada. Esse processo iterativo de construir um classificador com um limite de decisão ótimo é descrito como o processo de aprendizagem (PAL, M.; MATHER, P. M., 2005).

Na prática, as amostras de dados de várias classes nem sempre são linearmente separáveis e sobrepõem-se uns aos outros. Desta forma, SVM linear pode não garantir uma alta precisão para classificação (PAL, M.; MATHER, P. M., 2005).

Para lidar com dados não separáveis linearmente, variáveis adicionais (ou seja, variáveis de folga, extras) podem ser adicionadas à otimização SVM na abordagem de margem suave (PAL, M.; MATHER, P. M., 2005).

Cabe destacar que a ideia por trás do kernel é mapear o recurso espaço em uma dimensão superior (espaço euclidiano ou Hilbert) para melhorar a separabilidade entre as classes (MAULIK, U.; CHAKRABORTY, D. 2017). SVMs são particularmente atraentes no campo de SR devido à sua capacidade de gerenciar pequenos conjuntos de dados de treinamento de forma eficaz e muitas vezes oferecendo maior precisão de classificação em comparação com os

métodos convencionais (ROLI, F.; FUMERA, G., 2001). SVM é um classificador eficiente em espaços de alta dimensão, o que é particularmente aplicável para o campo de análise de imagem de SR onde a dimensionalidade pode ser muito grande (PAL, M.; MATHER, P. M., 2005).

2.6. Floresta Aleatória (*Random Forest*)

O *Random Forest* (RF) é uma abordagem de aprendizagem em conjunto, desenvolvida pela Breiman (2001), para resolução de problemas de classificação e regressão. O aprendizado conjunto é um esquema de aprendizado de máquina para aumentar a precisão integrando vários modelos para resolver o mesmo problema. Dentro Em particular, vários classificadores participam da classificação de conjunto para obter resultados mais precisos em comparação com um único classificador (Breiman, 2001).

Em outras palavras, a integração de múltiplos classificadores diminui a variância, especialmente no caso de classificadores instáveis, e pode produzir resultados mais confiáveis. A seguir, um cenário de votação é projetado para atribuir um rótulo a amostras não rotuladas (ZHOU, X. et al. 2016).

A abordagem de votação comumente usada é a votação por maioria, que atribui o rótulo com o número máximo de votos de vários classificadores para cada amostra não rotulada. A popularidade do método de votação majoritária deve-se à sua simplicidade e eficácia. Abordagens de votação mais avançadas, como o método de votação de veto, em que um único classificador veta a escolha de outros classificadores, pode ser considerada como uma alternativa para o método de votação por maioria (GHASEMIAN, N.; AKHOONDZADEH, M., 2018)

Os métodos de aprendizagem em conjunto amplamente utilizados estão impulsionando o *Bagging* (Ensacamento). O *Boosting* é um processo de construção de uma sequência de modelos, onde cada modelo tenta corrigir o erro do anterior um nessa sequência, porém dentro dos modelos construídos em RF, alguns sofrem o processo de *Overfitting* (Após a construção das arvores, chega a um por que o modelo estagna) (Figura, 12) (GIBSON, R. et al. 2020).




Figura 13. *Boosting random forest*. Fonte: GIBSON, R. et al. 2020

O ensacamento foi projetado para melhorar a estabilidade e a precisão de modelos integrados enquanto reduz a variação. Como tal, ensacamento é reconhecido por ser mais robusto contra o problema de sobre ajuste em comparação com a abordagem de reforço (WASKE, B. et al., 2012). O ADARF foi a primeira abordagem de ensacamento bem-sucedida, que foi desenvolvido a partir da combinação do ensacamento da Breiman abordagem de amostragem, florestas de decisão aleatória e a seleção de recursos introduzidos independente (WASKE, B. et al., 2012).

Estruturas de árvore e divisão significativamente das RFs de diferentes variáveis encorajam diferentes instâncias de *overfitting* e *outliers* entre os vários modelos de árvore de conjunto. Portanto, a votação de previsão final mitiga o *overfitting* no caso de problema de classificação, enquanto a média é a solução para os problemas de regressão (ZHANG, X. M. et al. 2017).

A RF gera árvores de alta variância e baixo viés. Portanto, novos conjuntos de dados de entrada (não rotulados) são avaliados em relação a todas as decisões árvores que são geradas no ensemble, e cada árvore vota a adesão de uma classe. Os membros com maioria de votos será o que for eventualmente selecionado (GIBSON, R. et al. 2020).

Para executar o modelo de RF, dois parâmetros devem ser definidos: O número de árvores (NA) e o número de árvores selecionadas com características aleatoriamente (CA). Os RFs são relatados como menos sensíveis ao NA comparado com CA (VANSELOW, K. A.; SAMIMI, C. 2014). A redução do parâmetro CA pode resultar em computação mais rápida, mas reduz tanto a correlação entre quaisquer duas árvores e a força de cada árvore na floresta e, portanto, tem uma influência complexa na precisão da classificação (VANSELOW, K. A.;

SAMIMI, C. 2014). Como o classificador de RF é computacionalmente eficiente e não super ajuste, NA pode ser o maior possível (ILIA, I., et al. 2018).

Diversos estudos encontraram 500 como um número ótimo para o NA porque a precisão não foi melhorada usando NA mais alto que isso número. Em contraste, o número de CA é um valor ótimo e depende dos dados disponíveis (CHEMURA, A, et al. 2017).

O classificador RF tornou-se popular para classificação, previsão, estudo de importância de variáveis, seleção de variáveis e detecção de outliers desde o seu surgimento em 2001 por Breiman (Breiman, 2001). Eles têm sido amplamente adotados e aplicados como um classificador padrão para uma variedade de tarefas de previsão e classificação, como aqueles em bioinformática (QI, Y. 2012), visão computacional [132] e SR para classificação da cobertura do solo (KULKARNI, A. D.; LOWE, B. 2016).

A RF ganhou sua popularidade na classificação da cobertura do solo devido ao seu processo de tomada de decisão claro e compreensível e excelentes resultados de classificação, bem como fácil implementação de RF em uma estrutura paralela para aceleração de computação de geo-big data (ZHANG, X. M. et al. 2017).

2.7. Classificador por redes neurais artificiais (Neural Networks)

Redes neurais artificiais (RNAs) são programas de computador projetados para simular o aprendizado humano processos através do estabelecimento e reforço de ligações entre os dados de entrada e os dados de saída. São estas ligações, ou caminhos, que formam a analogia com o processo de aprendizagem humano em que associações repetidas entre entrada e saída no processo de treinamento reforçam as ligações, ou caminhos, que podem ser empregados para ligar entrada e saída, na ausência de dados de treinamento (GONÇALVES, M. L. et al. 2008).

As RNAs são frequentemente representadas como compostas por três elementos. Uma camada de entrada consiste nos dados de origem, que em o contexto do sensoriamento remoto são as observações multiespectrais, talvez em várias bandas e de várias datas (GONÇALVES, W. G., et al. 2016).

A camada de saída consiste nas classes requeridas pelo analista. Estão incluídos os dados de treinamento nos quais a associação entre os rótulos de saída e os dados de entrada são claramente estabelecidos. Durante a fase de treinamento, uma RNA estabelece a associação entre dados de entrada e saída pelo estabelecimento de pesos dentro de uma ou mais camadas ocultas (ANDRADE, L. N., et al. 2013).

No contexto de associações repetidas de sensoriamento remoto entre classes e valores digitais, conforme expresso nos dados de treinamento, fortalecer pesos dentro de camadas ocultas que permitem que a RNA atribua rótulos corretos quando dados valores espectrais em ausência de dados de treinamento (Figura 13). Redes neurais artificiais têm sido empregadas para processar sensoriamento remoto multiespectral imagens e alcançaram maior precisão em comparação com os métodos estatísticos tradicionais (PIRES DE LIMA, R.; MARFURT, K., 2019).




Figura 14. Exemplo de funcionamento das redes neurais. Fonte: PIRES DE LIMA, R.; MARFURT, K., 2019

Aplicações de redes neurais ou modelos neuro-fuzzy no mapeamento de culturas têm sido exploradas por muitos pesquisadores, que demonstraram a capacidade do detector de recursos ponderados que permite a classificação de padrões e também a seleção de recursos (LI, R. et al. 2002). A rede proposta tenta selecionar características importantes entre as características plausíveis originalmente fornecidas, mantendo a taxa máxima de reconhecimento.

Experimentos foram realizados com dados do Landsat-TM e os resultados são comparados com os obtidos por outros classificadores. Os resultados mostraram uma melhora no desempenho de classificação usando o algoritmo de rede neural (CHUNJING, Y. et al. 2017). Qiu Fang (2008) desenvolveu o *Gaussian Fuzzy Learning Vector Quantização* (GFLVQ), que é um classificador de imagens supervisionado que faz uso de conhecimentos a priori no treinamento dados para atualizar um único neurônio sem retreinamento completo. Quando configurado com vários neurônios competitivos para cada classe, o GFLVQ é capaz de auto-organizar as amostras de treinamento em cluster espectral natural, aproveitando a capacidade de aprendizagem competitiva não supervisionada embutida no sistema.

Uma ferramenta de geovisualização também é desenvolvida para ajudar visualizar e entender o sistema especialista fuzzy e suas regras “se-então” por meio de gráficos de perfil

espectral fuzzy, permitindo que os usuários interajam com pixels individuais para explorar distribuições de amostragem (WANG, H. et al. 2009). O potencial de classificação do sub-pixel para estimativa de setentão área de cultivo, foi estudado por Verbeiren et al. (2006) usando tempo série de compostos NDVI mensais.

Vários modelos foram propostos por autores usando redes neurais. Wang, Y. e Jamshidi, M. (2007) propuseram *Hierarchical Fuzzy* Classificador de rede neural (HF) na classificação de dados de sensoriamento remoto. Na classificação HF cada sistema de rede neural *fuzzy* sistema é composto pelo classificador. Neste experimento a classificação de rede neural *fuzzy* sem a estrutura hierárquica precisou de 1152 regras. No meu mesmo contexto, Wui, W. e Guanglai, G., (2008) apresentaram modelo neuro-fuzzy para classificar uso do solo/cobertura do solo usando imagens Landsat 7 ETM+.

Com outra proposta, Howard, Daniel M., (2012) desenvolveu uma árvore de regressão modelo de classificação baseado em pontos de dados de treinamento derivados pelo Serviço Nacional de Estatísticas Agrícolas *Cropland*, utilizando a camada de dados em relação a uma variedade de outras variáveis ambientais de entrada relevantes para a previsão do tipo de cultura.

2.8. Estimativa de produtividade e imagens de satélite

A produtividade é uma parte do cultivo de cana-de-açúcar que tem a necessidade de ser prevista, por vários motivos, entre eles o de calcular a quantidade de moagem que será fornecida para a indústria e estimar capacidade de gerar açúcar e álcool. As técnicas de sensoriamento remoto permitem calcular a área de produção e a correlacionar resposta espectral com TCH (toneladas por hectares).

O estudo realizado por Hamar et al. (1996), com dados do Landsat 4 MSS combinado com um modelo agrometeorológico realizou a previsão de produtividade e mostrou capacidade de previsão com análise com dados, espectrais e agrometeorológico, isolados ou ambos integrados. A estimativa de produção calculada pelo modelo espectral, baseado no índice de vegetação, obteve menor coeficiente de diferença da produção real da estimada (Entre 5.1% e 7.7%) que agrometeorológico (Entre 8.2% e 23.5%). Contudo, o coeficiente de correção teve melhor resultado na relação entre produção e estimativa na ordem de (R²) 0.69 no modelo proposto com modelo por índice de vegetação e agrometeorológico em comparação com os modelos isolados (RUDORFF & BATISTA, 1990).

Em outra aplicação do Landsat 5 para a previsão de produção da cana-de-açúcar na Austrália não conseguiram resultados de correção entre a produtividade e a refletância para todas as bandas, apresentando um coeficiente de determinação (R^2) de apenas de 0,25. Assim, foi concluído que as variações em um período curto na condição do dossel foram independentes do crescimento da safra anterior ou da rebrota da soca (LEE-LOVICK & KIRCHNER, 1991).

Resultados de pesquisas na África do Sul investigaram o uso de satélite de resolução aproximada da NOAA/AVHRR e videografia multiespectral de alta resolução na tentaram de prever a produção de cana-de-açúcar para mensurar a capacidade de moagem de uma unidade industrial. Contudo, os resultados mostraram que não houve correlação significativa (R^2 0.5), entre o a produção estimada e o real colhido, na comparação com NDVI da videografia. (ARC 2000a, b). Os dados de NDVI do AVHRR para as condições de produção da África do Sul foram considerados satisfatório com correlação maior que R^2 0.7. (ARC, 2000 a,b)

No entanto, o sensor AVHRR apresentou correlação significativa com produtividade e NDVI estimado a área total da produção de uma usina e não conseguiu resultado satisfatório ao nível de área do tamanho de fazendas. (GERS, 2003a, 2004).

Uma alta correlação (acima de 0.79) de previsão de produção, foi apresentado na medição com espectrômetro de campo utilizando a mesma faixa do espectro que a banda B3 do Landsat ETM+, a razão do índice de vegetação (RVI), *Soil adjusted vegetation index* (SAVI) NDVI quando comparado com a resposta do número de planta/toceira por metro. (SIMÕES et al. 2005).

Para Ueno et al. (2005) que usou Landsat TM para estimar produção de biomassa da cana-de-açúcar no Japão, foram obtidos resultados do modelo proposto, com correlação mais que 0.6. Considerando que os talhões no Japão têm o tamanho máximo de 1 ha, o modelo apresentou potencial de uso para áreas de maiores ou com imagens de alta resolução espacial.

Com um método de ponderação de resposta espectral específicas considerando as restrições para a vegetação, Almeida et al. (2006) aplicaram o sensor ASTER com análises da área foliar converteu os valores de DN's da imagem em rendimento de cana por hectare ($t\ ha^{-1}$) por meio da normalização. O autor conseguiu resultado mais acurado do que os que já haviam sido aplicados anteriormente no Brasil para agroindústria.

A previsão de safra com método adotado usando ASTER por Almeida et al. (2008) teve eficiência e precisão se comparado com as forma utilizada pela agroindústria no período do estudo, porém verificou-se a necessidade de se usar dados auxiliares, tais como tipo de solo, topografia e variedade de cana-de-açúcar.

2.9. A vinhaça e o ciclo da cana

A cana-de-açúcar (*Saccharum* spp. Híbrido) é uma planta perene que cresce nos trópicos quentes por sua capacidade de produzir e armazenar altas concentrações de sacarose (GROF & CAMPBELL, 2001). O Brasil é o maior produtor mundial de cana-de-açúcar com uma produção de mais de 650 milhões de toneladas no ano-safra de 2020, representando mais de 40% da produção mundial (OLIVEIRA, 2020). As lavouras de cana-de-açúcar no Brasil são utilizadas para a produção de açúcar e etanol na proporção de 28%. O processo de produção da cana-de-açúcar tem sido associada a uma longa tradição de queima com graves implicações de poluição, mas a prática foi proibida no Brasil desde 2014 em favor de uma abordagem mecanizada. A cultura da cana-de-açúcar produz grande quantidade de matéria residual na forma de bagaço (bagaço) e um resíduo líquido viscoso conhecido como vinhaça.



Figura 15. Ciclo da produção e aplicação da vinhaça como sistema de irrigação e fertilizante (Fertirrigação).

Fonte: O autor

O processo produtivo começa com a locação de áreas agrícolas privadas pela empresa, que são preparadas para se transformarem em plantações de cana-de-açúcar. Esse processo

inclui preparo do solo, semeadura, aplicação de fertilizantes e inseticidas, irrigação, colheita, transporte e produção de etanol e açúcar (OLIVEIRA et. al., 2012).

A cana colhida é esmagada na planta industrial e a parte sólida (bagaço), é separada da parte líquida que é misturada à água no processo de fermentação. Após a fermentação, o etanol é separado deixando um resíduo líquido denominada vinhaça. A previsão é que no Brasil, para a safra 2020-2021, sejam produzidos até 29 bilhões de litros de etanol, o que também vai gerar 319 bilhões de litros de vinhaça (GALEANO, 2021).

A vinhaça é utilizada exclusivamente como fertilizante, pós-colheita, com duas funções: Humedecer o solo e fertilizar para a safra seguinte. Alguns processos atuais geram biogás a partir da vinhaça. O processo de aplicação da vinhaça como fertilizante é denominado \ fertirrigação (HAMADA, 2003). A vinhaça contém uma série de elementos químicos considerados bons fertilizantes (Tabela 3).

A fertirrigação com vinhaça é realizada logo após a colheita (até 20 dias) para evitar que as raízes da cana morram, pois, em média, a mesma planta pode ser colhida cinco vezes e até dez vezes em determinadas condições.

No entanto, cada colheita subsequente geralmente acarreta um custo de perda de produtividade de cerca de 10% em média. A vinhaça é levada para as plantações por meio de canais abertos ou caminhões. As fazendas utilizam tubagem de rebobinagem automática (hidro-roll) para pulverizar a vinhaça na plantação.

Tabela 3 - Principal composição química da vinhaça. Fonte: Embrapa, 2015.

Parâmetro	Intervalo
pH	4.4 - 4.6
Temperatura	80 - 100 C
Demanda de oxigênio	19800 mg/l
Nitrogênio (N)	480 - 710 mg/l
Fósforo (P ₂ O ₅)	9 - 200 mg/l
Potássio (K ₂ O)	3340 - 4600 mg/l
Cálcio (CaO)	1330 - 4570 mg/l
Magnésio (MgO)	580 - 700 mg/l
Sulfato (SO ₄)	3700 - 3730 mg/l
Carbono (C)	8700 - 12100 mg/l
Matéria orgânica	3800 mg/l

O processo de monitoramento da fertirrigação é difícil, pois depende da localização e a forma dos talhões de cada fazenda. Além de ser difícil monitorar, a cana depende de forma

crucial do processo, pois a produtividade depende diretamente não só da água no período mais seco, mas dos nutrientes que são aplicados em conjunto. Toda rede de aplicação depende estrutura de pessoas e máquinas agrícolas e quilômetros de tubulação para chegar até os talhões. Por exemplo, para uma plantação de 20 ha, o hidro-roll deve ser posicionado a cada 25 m e fertirrigar uma faixa de 350 m correspondente ao comprimento da tubulação do hidro-roll que irá rebobinar automaticamente, seguindo uma dinâmica de vazão e tempo de aplicação para lançar a quantidade ideal (DE OLIVEIRA et. al., 2020).

Outros fatores afetam a produtividade do campo da cana-de-açúcar, como pragas e doenças ou mau preparo do solo, mas a fertirrigação com vinhaça é o mais crítico, principalmente logo após a colheita, mesmo nas melhores condições, se a plantação não for fertirrigada ou se vier também tarde, a produção cairá drasticamente.

O processo de fertirrigação ocorre 24 horas por dia após a colheita e exige um bom sincronismo, pois uma velocidade de pulverização insuficiente provocará inundações nos canais da vinhaça e causará impactos ambientais negativos ao atingir os riachos ou lençol freático (DA SILVA, 2014).

As áreas irrigadas em cana-de-açúcar é uma operação de alto custo financeiro e requer execução de procedimentos que, exige sincronia entre tempo, área aplicada, risco ambiental e, se não feito com precisão, prejudica o desenvolvimento da produção. O manejo da irrigação é alvo tecnicamente interessante para direcionar as pesquisas sobre sensoriamento remoto e desenvolver métodos de análise do que corre dentro do talhão (LEAL, et al. 2013)

2.10. Cenário internacional das agências espaciais de governo para agricultura

Para evidenciar a escalada das aplicações de SR na agricultura, que ajuda a fundamentar a necessidade de segurança alimentar e produção de energia em várias partes do mundo, as agências de fomento de satélite NASA e ESA, tem em seu portfólio programas voltados para agricultura. Esses programas são direcionados para pesquisa e desenvolvimento para trazer novas aplicações na agricultura com sensoriamento remoto (CAMPS, 2020).

O programa NASA Harvest é um consórcio coordenado pela universidade de Maryland no centro global de pesquisa e monitoramento agrícola. Esse programa, iniciado em 2017, tem como base o uso de sensoriamento remoto para monitorar o uso da terra agrícola, sustentabilidade agrícola e produtividade agrícola. As pesquisas e aplicações são em escala de fazenda a global com pesquisas usando dados de drones, satélites óticos, SAR e meteorológico (WHITCRAFT, 2020).

No programa da NASA existem projetos como, o “Mapeamento do tipo de colheita em escala de campo e estimativa de rendimento” e o “Mapeamento da produção e perda usando dados de satélites” (NAKALEMBE, 2021).

Em uma medida que poderia beneficiar cerca de 22 milhões de agricultores, a Política Agrícola Comum da UE entrou na era espacial. Oferecendo informações detalhadas e oportunas sobre culturas e terras agrícolas, o *Copernicus Sentinels* está sendo usado para simplificar e modernizar essa política da UE que mais serve (FRECO & POPPE, 2016).

O Sentinel-2B se juntou ao satélite Sentinel-2A e aos outros Sentinels que fazem parte do programa Copernicus, o programa de observação da Terra mais ambicioso até o momento. O Sentinel-2A e 2B fornecem 'visão de cores' para o Copernicus e, juntos, podem cobrir todas as superfícies terrestres uma vez a cada 5 dias, otimizando a cobertura global e a entrega de dados para diversas aplicações. Atualmente é o satélite mais usados na aplicação em agricultura em todo o planeta, devido sua qualidade de dados e alta frequência de revisita para um satélite de média resolução (SIMEK, 2018).

A agricultura de precisão tem sido fortemente apoiada pelos dados dos satélites Sentinel 2, que com o tempo de revisita alta e qualidade dos dados. A ESA está atualmente trabalhando com a Comissão Europeia e as partes interessadas nacionais para entender toda a gama de oportunidades que a Observação da Terra pode contribuir, em particular para modernizar e simplificar a Política Agrícola, que está sendo uma ferramenta para a segurança alimentar no planeta (GASCON, 2020).

Existem, atualmente vários trabalhos e programas que mostram como a agricultura se beneficia do uso dos dados do Sentinel pela Europa. O uso de satélites para monitorar as lavouras e apoiar sua gestão está tendo cada vez mais atenção. A resolução temporal, espacial e espectral melhorada da Agência Espacial Europeia (ESA) que lançou a plataforma gêmea Sentinel-2 A + B está abrindo caminho para sua popularização em agricultura de precisão. Além das características técnicas da constelação Sentinel-2 A + B, a natureza de acesso aberto do as informações que eles geram e o software de suporte disponível são uma melhoria significativa para monitoramento agrícola. Este trabalho foi motivado pelos desafios enfrentados por pesquisadores e instituições agrárias que entram neste campo; visa enquadrar os princípios de sensoriamento remoto e Sentinel-2 aplicações na agricultura (HUANG, 2018).

Assim, os recursos e usos do Sentinel-2 em agricultura de precisão incluem detecção de estresse abiótico e biótico, e manejo agrícola. Em contraste com outras imagens de satélite, a plataforma gêmea Sentinel-2 A + B aumentou significativamente os recursos para monitoramento e manejo de culturas em todo o mundo (SAGARRA, 2020).

Em relação ao monitoramento do estresse da cultura, as capacidades do Sentinel-2 para a detecção de estresses abióticos e bióticos representam um grande passo em muitos aspectos, embora não sem limitações. Portanto, combinações de dados de campo e diferentes técnicas de sensoriamento remoto ainda podem ser necessárias. O Sentinel-2 tem uma ampla gama de aplicações úteis na agricultura, mas ainda com espaço para melhorias adicionais. Formas atuais e futuras que o Sentinel-2 pode ser utilizado também são discutidos (CSILLIK, 2019).

Muitas aplicações futuras que incorporam o sensoriamento remoto na gestão agrônômica construirão sobre os fundamentos das abordagens tradicionais. Uma das capacidades subdesenvolvidas em sensoriamento é o valor de combinar diferentes IVs (Índices de Vegetação) para estimar a produtividade da cultura (GITELSON & MERZYAK, 1997).

Os IVs individuais têm padrões espaço-temporais em culturas e solos, mas esses dados podem precisar ser emparelhados com outras fontes de dados, como modelos de culturas ou dados meteorológicos, para fornecer informações significativas para as decisões de gestão. Um exemplo desta abordagem é fornecido por Claverie et al. (2012) para milho e girassol, onde combinaram os padrões sazonais de área foliar verde com biomassa vegetal ao longo da estação de crescimento. Combinaram o crescimento e a senescência fase de desenvolvimento para estimar o rendimento das culturas com base no uso de dados de sensoriamento remoto para incorporar em um modelo de crescimento de culturas. A concordância com os rendimentos observados foi aceitável para o girassol, mas mostrou diferença considerável para a cultura do milho.

Enquanto Guan et al. (2017) identificaram que várias bandas de onda poderiam estimar os rendimentos das colheitas, verificaram também que emparelhar esses dados com dados meteorológicos era necessário para estimar a colheita parâmetros de crescimento. Zarco-Tejada et al. (2016), examinaram o uso da fluorescência da clorofila para estimar fotossíntese líquida como base das decisões de agricultura de precisão. Produtividade primária bruta foi examinado por vários pesquisadores ao longo do tempo (GITELSON et. al., 2006), e um dos esforços recentes foi combinar clorofila com um índice de refletância fotoquímica (ZHANG et. al., 2016).

Uma das grandes limitações para o uso de ferramentas de sensoriamento remoto entra-se no fato de que o desenvolvimento da cultura deixa uma grande quantidade de solo exposto até que a cultura cubra completamente o solo. Antes da colheita cobrir completamente o solo, os IVs representam uma combinação de refletância da planta e do solo. Utilização do índice de clorofila para estimar o status de nitrogênio da cultura tem sido objeto de vários estudos que utilizaram valores de reflectância da banda (DAUGHTRY et. al., 2000).

3. MATERIAIS E MÉTODOS

A sequência do trabalho, na concepção da proposta metodológica, a aplicação de imagens de satélite ótico (Sentinel 2), satélite por radar (Sentinel 1) e foi usado fotografia aérea por RPA para apoiar no registro das características da irrigação por aspersão. Assim, foi possível identificar, classificar e monitorar o processo de fertirrigação com vinhaça no processo de produção de cana-de-açúcar.

A identificação das áreas fertirrigadas da empresa parceira, que forneceu os dados, foi comparada com produtividade (TCH) ao longo de 4 safras, para avaliação da variação da qualidade no manejo da fertirrigação e o comportamento evolutivo da produtividade com respostas dos dados de sensoriamento remoto.

Em uma segunda etapa foi estudado a capacidade de classificadores por segmentação na identificação das áreas com lançamento de vinhaça. A terceira etapa testou modelos de classificação *Lage Scale Mean Shift* (LSMS) que tem parâmetros de orientador ao objeto na entrada no algoritmo.

A iniciativa foi gerar uma metodologia que se aplique de forma automatizada para qualquer área fertirrigada com vinhaça.

A seguir é apresentado o fluxograma metodológico para melhor visualização da sequência (Figuras 15).

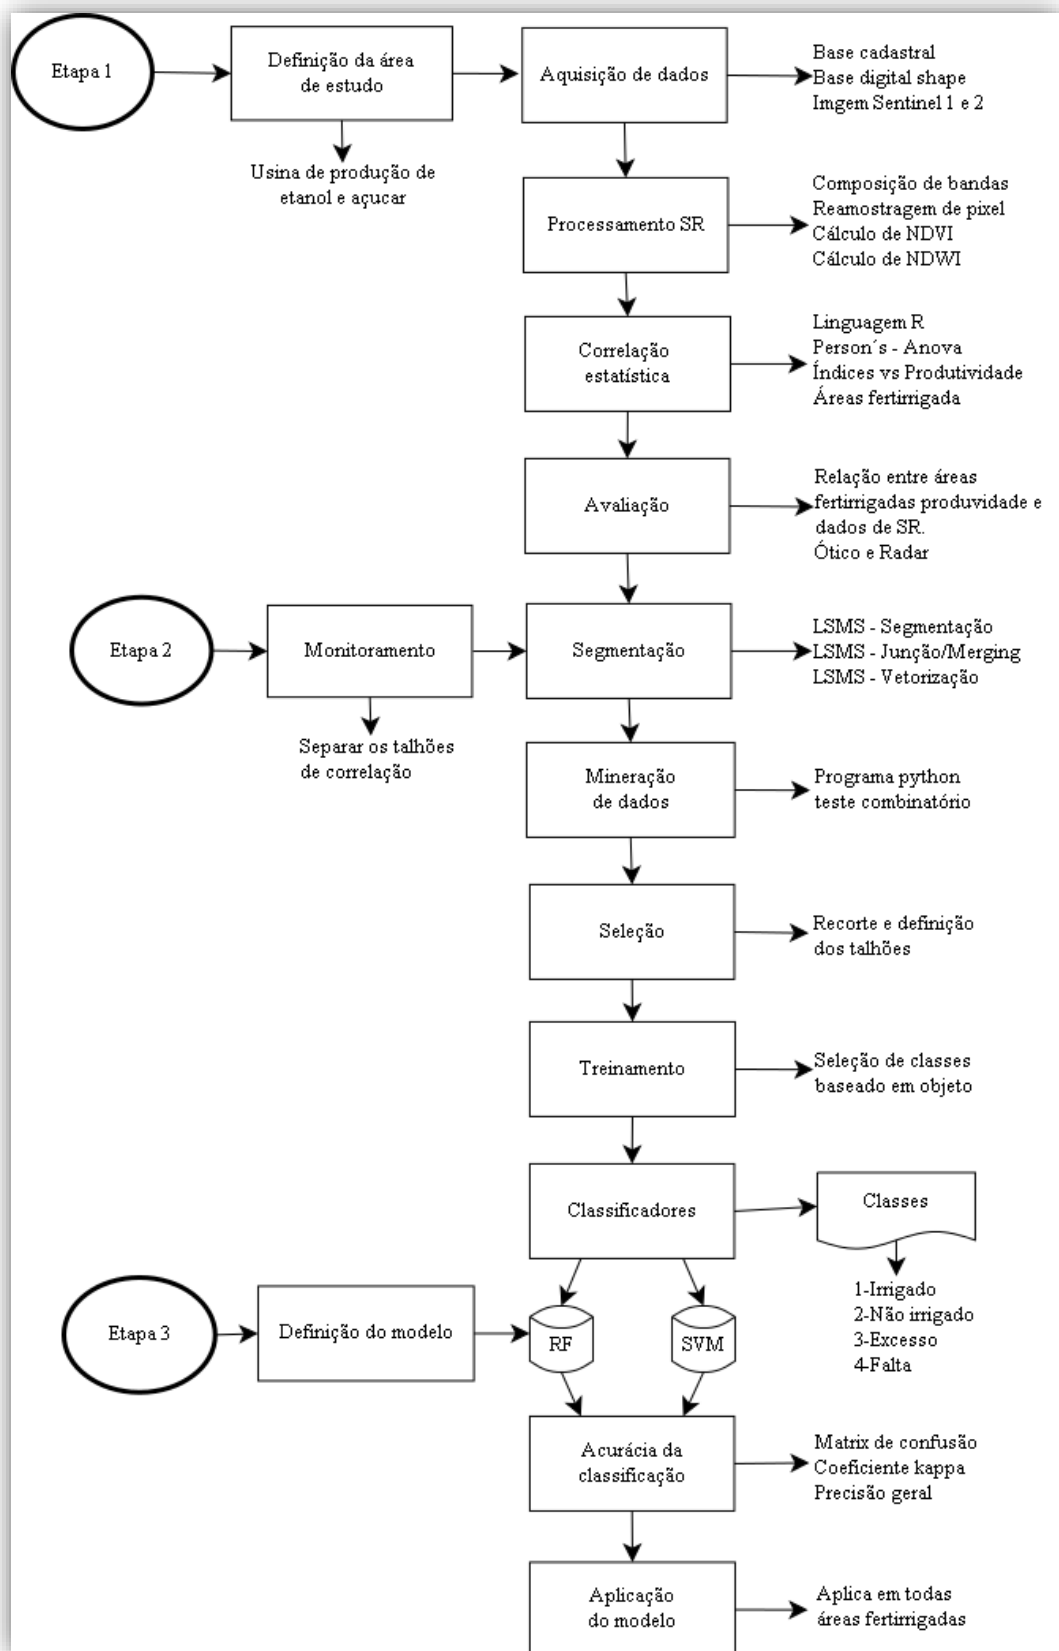


Figura 16 - Fluxograma e etapas do trabalho. Aquisição dos dados, processamento, segmentação e classificação. RF (*Random Forest*), SVM (*Support Vector Machine*). Fonte: o autor.

No fluxograma é apresentado o software utilizado, e a tabela 4 abaixo explica a função e a sequência de aplicação de cada um

Tabela 4. Softwares aplicados na pesquisa

<i>Software</i>	Propriedade	Função
QGIS	Livre	Manipulação de <i>shapefile</i> , imagens, dados cadastrais e elaboração de mapas
SNAP	Agência espacial europeia	Processamento digital de imagens, extração de índices espectrais
Orfeo Tool Box	Agência espacial Francesa	Segmentação e classificação orientadas ao objeto
R	Livre	Análise estatística
Python	Livre	Criação do programa para teste de combinações de segmentação

3.1. Área de estudo

A área de estudo com os talhões de cana detalhando a área de produção está localizada no extremo sul do estado de Goiás, próximo à divisa com Minas Gerais e Quirinópolis (Figura 16 e 17). A área está na bacia do rio Paraná, dividida em 668 campos (mostrados em amarelo na figura) de tamanhos variados, todos dentro da área de produção de São João Cargill- SJC Bioenergia –empresa multinacional que gentilmente forneceu os dados usados para este estudo. Esses campos ocupam uma área de 150 mil ha de cana-de-açúcar sob o controle da SJC, que produz 15 milhões de toneladas de cana-de-açúcar.

Trata-se de uma área que recebe aproximadamente 1500 mm de chuva por ano, principalmente concentrada entre os meses de outubro a abril. Tem uma temperatura média de 25 °C e o terreno é ligeiramente inclinado com declives de até 6%. Os solos são considerados ricos e variam entre arenosos e franco-argilosos.

No processo de fertirrigação é executado com um padrão de manejo, definido pela montagem da rede de tubulações que devem seguir uma sequência padronizada. Assim, os equipamentos (*Hidro roll*) são esticadas dentro do talhão com espaçamento entre as mangueiras definido para que haja sobreposição da aplicação do aspersor no arco de 180 graus. O Controle do manejo no posicionamento dos aspersores é um dos principais fatores de falha durante processo da fertirrigação, seguido pela calibração da pressão e condições da velocidade do

vento. Para evidenciar as características das áreas de fertirrigação foi registrada para apresentar a forma de manejo e aplicação da vinhaça (Figura 17).

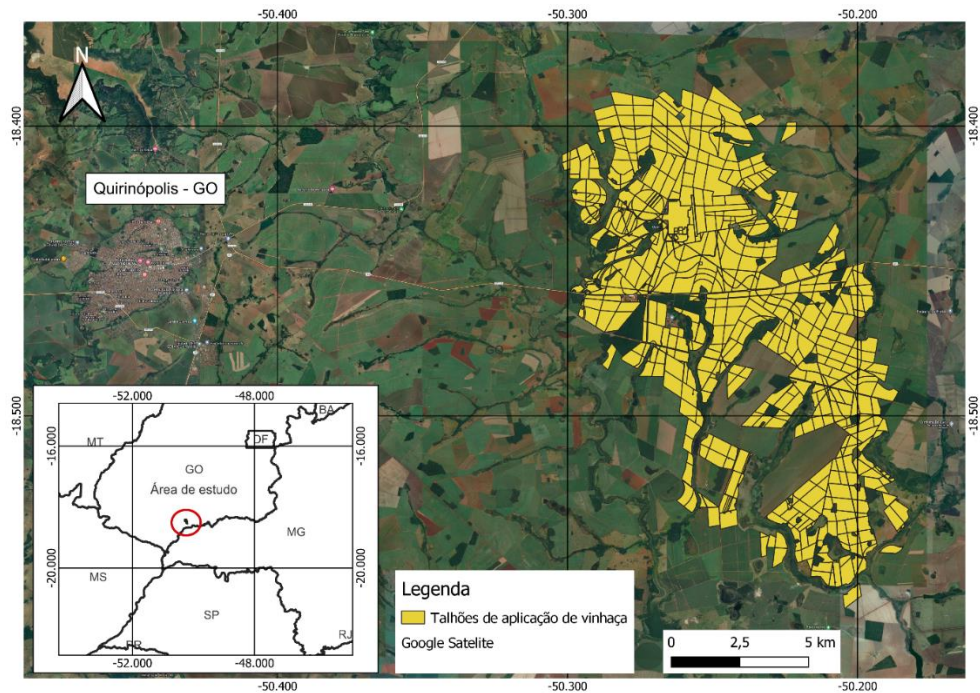


Figura 17. Local da área de estudo com sob a imagem infravermelho de abril de 2019 com os principais talhões e amarelo.

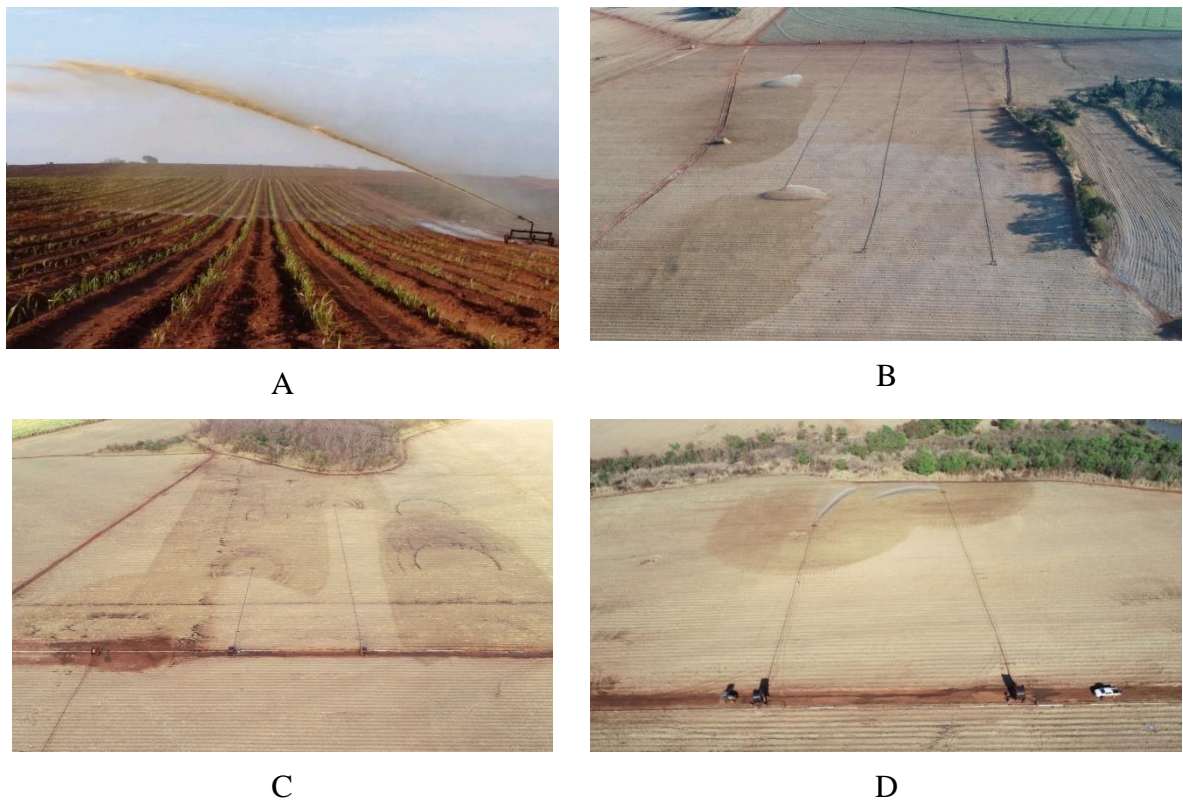


Figura 18. Caracterização das áreas de fertirrigação: A) foto do canhão aspersor lançando a vinhaça. B, C, D) Fotos de drone exemplificando o formato e as manchas da aplicação. Fonte: o autor.

3.1.1. Dados auxiliares

Os dados auxiliares foram fornecidos pela São João Cargill S.A. e consistiam em dados coletados por apontamento em sistema pós colheita em áreas de tamanho variado (entre 1 e 60 há cada talhão). Contêm a descrição detalhada de cada estande que serviu para fazer a seleção dos estandes a serem analisados com base em alguns critérios. As arquibancadas deveriam:

- estar localizado dentro da bacia hidrográfica da vinhaça, onde a vinhaça é espalhada usando pompons e tubos longos (alguns as plantações não recebem vinhaça ou a recebem usando métodos diferentes (principalmente caminhões),
- ser da quarta ou quinta safra, e
- possuem dados de descrição completos.

A quarta e quinta safras significam que a cana estava no quarto ou quinto ano de crescimento. Este foi um critério importante já que a produtividade da cana cai cerca de 10% ao ano para a mesma planta. Após alguns anos (até oito ou nove), as plantas de um talhão são completamente removidas e uma nova semeadura é aplicada.

3.1.2. Imagens e processamento de imagens

As imagens Sentinel-1 e -2 foram baixadas do Sentinel Datahub da ESA para cobrir os anos de 2018 e 2019 quando a cana estava madura para comparar com os dados da colheita de 2019. Um único bloco de imagem cobre toda a área de estudo. Apresenta-se o modelo da composição (Figura 18).

As imagens S-2 foram analisadas com software SNAP (ESA, 2020) que fornece dados de reflectância diretamente. O programa SNAP foi desenvolvido para processamento de imagens de satélite, com foco nas plataformas orbitais da ESA. As etapas de processamento:

1. Carregamento do arquivo direto no arquivo zip.
2. Reamostragem das bandas
3. Recorte da área de interesse
4. Extração de estatísticas das bandas da área de estudo

As imagens S-2 têm 13 bandas espectrais diferentes com três resoluções diferentes: 10, 20 e 60 m. As três bandas de 60 m têm aplicações muito específicas, a saber, uma banda de

aerossol costeiro (banda 1), uma banda de vapor de água (banda 9) e uma banda de nuvem cirrus (banda 10).

As três bandas foram usadas nesse estudo apenas em imagens livres de nuvem e de alta qualidade, pois além de alterar a característica radiométrica e gastar tempo de processamento, o período do estudo é raro a presença de nuvens na região. Quatro bandas têm uma resolução de 10 m e seis bandas têm uma resolução de 20 m, que foram reamostradas para 10 m usando um algoritmo bilinear, vizinho mais próximo e foi comparado os resultados.

A imagem S-2 foi então cortada na extensão da área de estudo definida pela extensão dos polígonos testados. Os polígonos dos talhões selecionados foram sobrepostos à imagem para dar uma ideia da área estudada. SNAP também foi usado para produzir um índice de vegetação e um índice de água. Dados os vários índices disponíveis, ao invés de classificar automático, foi escolhido por inspeção seguindo análise de áreas pós-colheita em zonas de fertirrigação nas fazendas para análise.




Figura 19 - Composição colorida das imagens S-2 (a) e S-1 (b) de 2 de agosto e 1 de agosto de 2018, respectivamente. A imagem colorida S-2 corresponde ao composto "Healthy vegetation" (proposto pelo programa aplicativo SNAP) (IR em vermelho, SWIR em verde, azul em azul). A imagem S-1 é representada com a seguinte composição: VV em vermelho, VH em verde e VV-VH em azul. Fonte: o autor.

As imagens S-1 também foram processadas com SNAP para remover ruído de *speckel* (Efeito de salpicamento), aplicar correção de terreno alcance-Doppler e aplicar o filtro de remoção de manchas de Lee (SHUKLA, 2017). As imagens S-1 vêm com duas bandas de polarização: VV e VH. Uma razão entre VV e VH foi adicionada como uma terceira variável. Como as imagens S-2, essas imagens foram recortadas na extensão da área de estudo.

O processamento das imagens consistiu principalmente na extração de parâmetros estatísticos das imagens de cada estande. Para cada talhão foram extraídas as seguintes variáveis: média, desvio padrão, mediana, valor mínimo e valor máximo. Esta operação foi realizada usando algoritmo do modulo “*Objects Radiometric Statistics*” do *Orpheo Tool Box* (OTB) (GRIZONNET et. al., 2017) e usando um *shape file* dos campos selecionados.

3.1.3. Médias de produção e dados de SR das safras recentes

Com o passar dos anos, dados são gerados a cada safra, e o acesso a esses dados possibilitou o estudo das médias. Para fazer a análise das médias, foi acessado o banco de dados da empresa (SJC Bioenergia) que disponibilizou os dados de TCH, ATR (Produção de açúcar por hectare) quantidade de colheita (Corte). Para os dados de SR, foram baixados os dados de abril de 2018, abril de 2019, abril de 2020 e abril de 2021. As imagens foram selecionadas para mês de abril de cada devido ser o mês de pico de crescimento da cana, ou seja, representa a reposta máxima da planta no crescimento da vegetação. Esse pico de crescimento no mês de abril acontece em consequência de a cana receber todo o volume de chuvas do período mais chuvoso da região de estudo (outubro a maio).

Foi comparado as variações das médias do índice NDWI, que utiliza imagem reamostrada, no método bilinear e vizinho mais próximo (VP) para analisar se existe diferença nos resultados.

3.1.4. Teste estatístico

Para determinar uma abordagem para identificar problemas no processo de fertirrigação, surgiram algumas dificuldades. Em primeiro lugar, o período de colheita se estende entre abril e novembro, o que significa que várias imagens precisaram ser utilizadas para contemplar todo o período. Em segundo lugar, como as mesmas plantas de um campo podem ser colhidas várias vezes com uma diminuição na produtividade, a tonelagem não pode ser usada diretamente como uma variável dependente. Em terceiro lugar, e a dificuldade mais importante, a produtividade não é medida por talhão, por fazenda, o que pode dificultar a identificação de problemas de fertirrigação, uma vez que uma fazenda pode ter talhões com e sem problemas de fertirrigação.

Para melhor isolar o problema, foram identificados visualmente campos com problemas de fertirrigação (com aspecto heterogêneo pelo menos na data da imagem) e campos com espalhamento homogêneo da vinhaça para formar dois grupos. Apresenta-se o aspecto visual

de alguns campos com problemas de fertirrigação em uma imagem *Google Earth*, em uma composição de imagem S-2 de várias datas e na composição de cores de multipolarização de uma imagem SAR S-1 (Figura 19).




Figura 20 - Ilustração do problema de fertirrigação que causa estresse nutricional em algumas lavouras de cana-de-açúcar: (a) Imagem do mapa do Google mostrando uma leve diferença de tom; (b) imagem composta S-2 de SAVI de três datas (agosto, setembro e novembro de 2018); (c) Imagem composta colorida S-1 (VV, VH, VV VH). Fonte: o autor.

Para tentar trazer à tona os problemas de fertirrigação, várias abordagens estatísticas foram testadas e são apresentadas na seção de resultados: 1) Correlação de Pearson entre tonelagem de cana-de-açúcar por hectare (TCH) e as diferentes bandas e índices S-2, bem como o S-1 polarização e razão de polarização; 2) Análise de Variância (ANOVA) para testar se campos com problema de fertirrigação podem pertencer a um grupo diferente dos campos sem estresse nutricional e para identificar as bandas, polarização e índices que melhor separam os dois grupos.

Para os dados de SR foram calculados NDVI e NDWI para o período de 2018 a 2021. Aplicou-se o teste de normalidade de Shapiro-Wilk (CARREIRAS, J. M. et al. 2006) e as amostras apresentaram $p < 0,05$ representando normalidade para as análises sequenciais. Para avaliação da correlação foi filtrada a base de dados, utilizando somente talhões acima de 5 hectares, para se ter a representatividade nos dados de SR, assim como os talhões em que houve produção durante todo as safras.

A correlação múltipla foi aplicada devido à quantidade de variáveis analisadas (11 variáveis) e com mais de 600 amostras para cada variável (FOLHES, M. T. et al. 2009). Para validar a correlação múltipla, foi realizado o teste de confiabilidade a Anova (TRORP, K. R., & TIAN, L. F. 2004). Todas da análises estatísticas foram realizadas utilizando o programa R (R core team, 2022).

3.2. Processo da classificação orientação orientado a objeto

3.2.1. Aquisição de dados

As imagens do satélite Sentinel 2 e 1, do portal da Copernicus (<https://scihub.copernicus.eu/>) e dados geoespaciais das áreas de produção de cana-de-açúcar fornecidos pela empresa SJC Bioenergia. As imagens Sentinel 1 e 2 apresentam um conjunto de características (Figura 20).

Sensor	Dados e combinações	características	
Sentinel-1	Polarization	VV VH V/H ¹	vertical transmit-vertical channel vertical transmit-Horizontal channel VV/VH
	Texture ²	VH_CON, VV_CON VH_DIS, VV_DIS VH_HOM, VV_HOM VH_ASM, VV_ASM VH_ENE, VV_ENE VH_MAX, VV_MAX VH_ENT, VV_ENT VH_MEA, VV_MEA VH_VAR, VV_VAR VH_COR, VV_COR	Contrast Dissimilarity Homogeneity Angular Second Moment Energy Maximum Probability Entropy GLCM Mean GLCM Variance GLCM Correlation
Sentinel-2	Multispectral bands	B2	Blue, 490 nm
		B3	Green, 560 nm
		B4	Red, 665 nm
		B5	Red edge, 705 nm
		B6	Red edge, 749 nm
		B7	Red edge, 783 nm
		B8	Near Infrared, 842 nm
		B8a	Near Infrared, 865 nm
		B11	Short Wave IR, 1610 nm
		B12	Short Wave IR, 2190 nm
Sentinel-2	Vegetation indices	NDVI ³ NDI45 ⁴ IRECI ⁵ TNDVI ⁶	$(\text{Band 8} - \text{Band 4}) / (\text{Band 8} + \text{Band 4})$ $(\text{Band 5} - \text{Band 4}) / (\text{Band 5} + \text{Band 4})$ $(\text{Band 7} - \text{Band 4}) / (\text{Band 5} / \text{Band 6})$ $I(\text{Band 8} - \text{Band 4}) / (\text{Band 8} + \text{Band 4}) + 0.51^{1/2}$

Figura 21 - Características da imagem Sentinel 1 e 2. Fonte (DENIZE, JULIEN, et al.)

3.2.2. Sentinel Application Platform (SNAP)

O programa SNAP é uma ferramenta com grande poder de processamento de dados de sensoriamento remoto, certamente uma das mais completas ferramentas disponíveis de forma gratuita pela Agência Espacial Europeia - ESA. A arquitetura SNAP é ideal para o processamento e análise de Observação da Terra (OT) devido às seguintes inovações tecnológicas: Extensibilidade, Portabilidade, Plataforma Modular *Rich Client*, Gerenciamento de memória lado a lado e uma Estrutura de processamento de gráficos. Para preparar os dados sentinel para análises consideramos a melhor ferramenta (SNAP, 2020).

3.2.3. Orfeo *ToolBox* (OTB)

O projeto desenvolvido pelo CNES é um pacote de ferramentas de código aberto específico para processamento de imagens de sensoriamento remoto (WWW.orfeo-toobox.org, acessado em 01 de agosto de 2019). A biblioteca para análise de imagens é grande, de fácil acesso e de manipulação simples assim como por linha de comando ou usando diretamente cada algoritmo separadamente (INGLADA & CHRISTOPHE, 2009).

Para realizar a segmentação no OTB, existem algumas ferramentas de segmentação, nesse trabalho foi utilizado a versão 7.0 e o algoritmo *Large-Scale-Mean-Shift* (LSMS). É importante registrar que o OTB tem atualizações frequentes, e que os algoritmos têm melhorias na evolução das versões. O programa tem classificadores de código aberto orientado a objeto, que nesse trabalho foi abordado, RF (*Random Forest*), RFS (*Random Forest Shark*), além de SVM e Redes Neurais, para classificação supervisionada orientada a objeto (CNES, 2020).

O OTB foi desenvolvido para facilitar o processamento de dados pesados por ser muito leve e fácil manipulação em computadores comuns. A maior dificuldade do OTB é na visualização dos dados que, é possível, mas limitada. Neste caso foi utilizado o programa QGIS (www.qgis.org acessado em 02 de novembro de 2019) para visualização e análise dos dados (acessado em 01 de agosto de 2020) na versão 3.6.3.

3.2.4. Processamento

Como descrito em Immitzer et al. (2016), o primeiro passo foi normalizar cada banda para um intervalo com um de valores a fim de reduzir o efeito de possíveis outliers na segmentação (Figura 21).

Para processar as imagens definiu-se utilizar 9 bandas que compreendem o visível B2, B3, B4 do infravermelho próximo B8, RedEdge B5, B6, B7 e do infravermelho de ondas curtas o B11 e B12. Esse intervalo de bandas foi selecionado para abranger o máximo de bandas dentro da faixa espectral do infravermelho. As bandas utilizadas são referência para utilização em aplicações na agricultura utilizada pela *Europe Space Agency* (ESA) (GOMARASCA et al. 2019).

A pesquisa e as análises se configuram somente dentro do talhão, as variações sutis na superfície do talhão, indicam resposta de alguma alteração no estado do solo ou da planta, que refletem ou é correlacionada a problema no manejo (FILIP, et al., 2020). Dado a necessidade

de identificação da variação de valores no pixel dentro do talhão, o máximo de informações no infravermelho contribuiu no registro das pequenas mudanças dentro do talhão (MARTINS & ROSA, 2019).

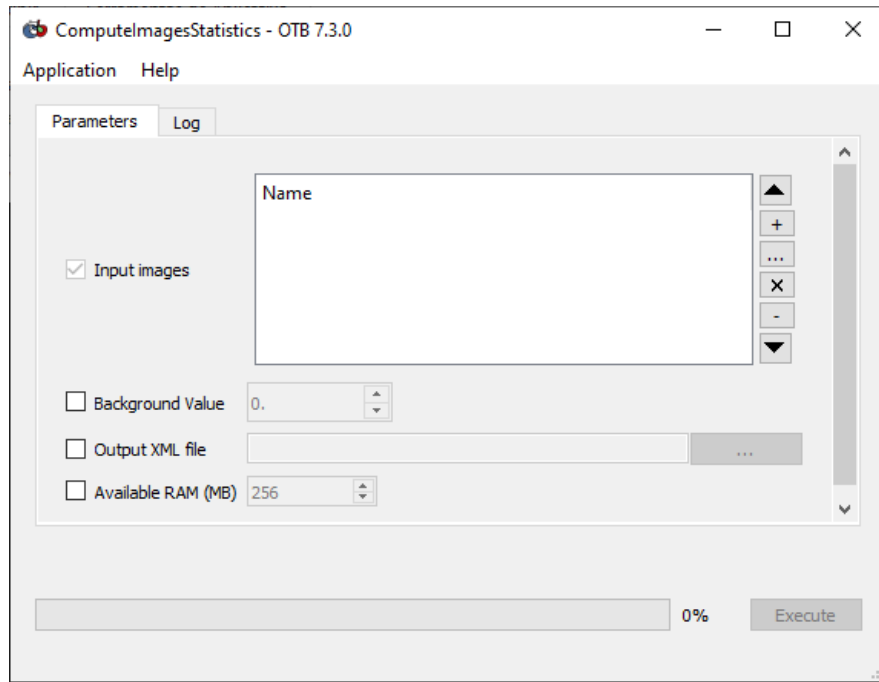


Figura 22 - Algoritmo para computar estatística e normalizar as bandas da imagem de satélite - Orfeo Toolbox.
Fonte: o autor.

Para fazer o empilhamento foi aplicada uma reamostragem de pixel das bandas de 20m para 10m usando modelo bilinear. Após a reamostragem as 9 bandas, foi empilhado as bandas em um único arquivo, necessário para processar utilizando o OTB. A reamostragem é um processo que exige muita capacidade de processamento e, o programa SNAP (*Sentinel application platform*) usado para reamostragem (Figura 22), necessitou um computador com capacidade de processamento específica para realizar o procedimento.

Com todas as bandas espectrais de interesse na mesma resolução espacial, prosseguiu-se com um recorte espacial da área de interesse. As áreas de interesse foram selecionadas de acordo com levantamento em campo e dados de operacionais, como data de início da irrigação. As imagens foram exportadas para o formato .tiff e os passos seguintes foram executados pelo programa OTB.

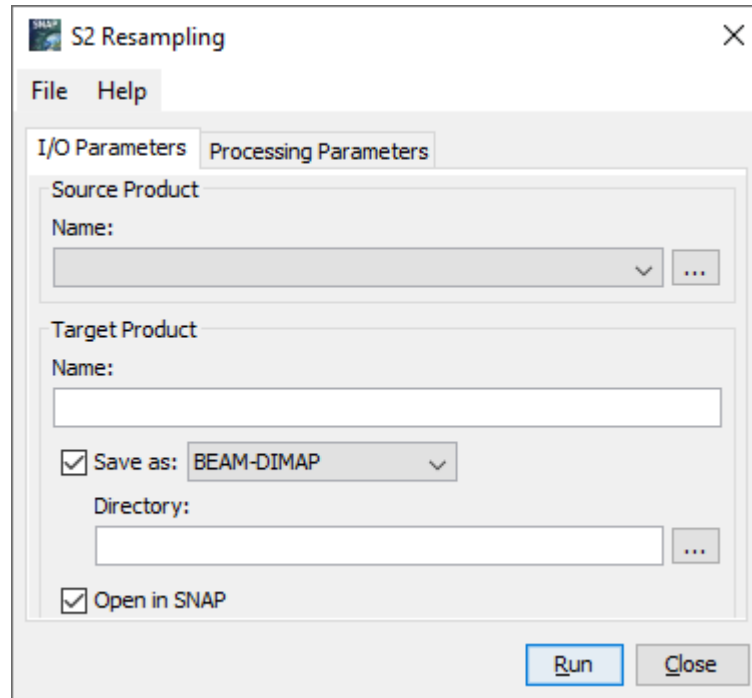


Figura 23- Comando *Resample* para reamostragem de pixel igualar resolução espacial entre bandas. Disponível no algoritmo vizinhos mais próximo, bilinear e bicubica. Fonte: o autor.

Para realizar a segmentação, foi necessário realizar um processo de testes para se chegar em um limiar de delimitação de polígonos que fosse condizente com o objetivo de extrair área homogêneas da variação da condição da planta dentro do talhão. Esse processo requer um conhecimento prévio do objeto de estudo, devido as particularidades do processo de produção e manejo da cana. Para identificar de forma a criar parâmetros que direcione uma análise dos problemas na cultura da cana, foi necessário testar dezenas de parâmetros para encontrar o que mais se aproximava de variações consideráveis para gestão na cultura da cana.

3.2.5. Separabilidade espectral (Se as classes são separáveis)

Para medir a separabilidade das camadas do SAVI e NDWI das bandas (2, 3, 4, 5, 6, 7, 8, 11, 12) do S2 de diferentes variações da vegetação presentes na área de estudo dentro dos talhões (Vigor pleno, vigor médio, Vigor baixo, Falha no crescimento, mancha de anomalias), foi aplicado a estatística-M, conforme definida originalmente por Kaufman e Remer e modificada por De Luca, et al (2019), apresentada na fórmula a seguir.

$$M = (\mu_1 - \mu_2) / (\sigma_1 + \sigma_2)$$

Onde μ_1 é o valor médio para a classe 1, μ_2 é o valor médio para a classe 2, σ_1 é o desvio padrão para a classe 1 e σ_2 é o desvio padrão para a classe 2. M-statistic expressa a diferença entre (o sinal) normalizado pela soma do desvio padrão que pode ser interpretado como o ruído, ou seja, a separação entre duas amostras por distribuição de classe. Valores maiores levam maior sobreposição das duas bandas consideradas e, portanto, a menor separabilidade. Se $M < 1$, as classes sobrepõem-se significativamente e a capacidade de separar (isto é, discriminar) as regiões é fraca, enquanto que se $M > 1$, as médias de classe estão bem separadas e as regiões são relativamente fáceis de discriminar.

3.2.6. Segmentação

A etapa foi iniciada com o processo que subdivide a imagem em objetos (segmentos), representados por polígonos adjacentes formados por um conjunto de informações com as mesmas características dentro de cada polígono. Os pixels presentes dentro de cada segmento delimitado apresentam uma homogeneidade de valores e dependendo dos parâmetros estabelecidos, homogêneo na forma (LU, D., & WENG, Q., 2007). Para esse trabalho o processo foi realizado no *orfeo toolbox* (Figura 23).

Para caracterizar um objeto na forma de um objeto notável, ele deve representar um alvo real na superfície da imagem. O grande destaque da segmentação que ela se baseia, além das propriedades radiométricas do pixel, na estrutura da imagem e informações de cor, intensidade, textura, trama, forma contexto, relações dimensionais e posição (ARVOR, D., et al 2013).

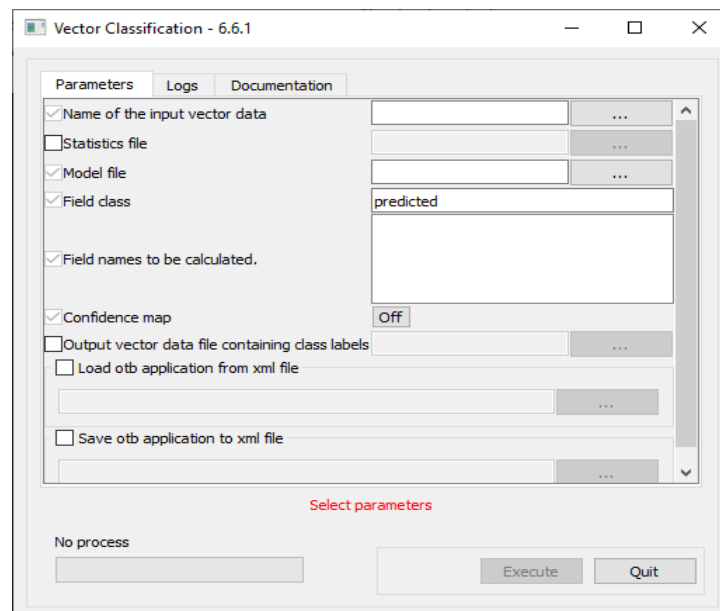


Figura 24 - Configuração para segmentação. Fonte: o autor.

No processo de segmentação, foi necessário realizar um processo de testes para chegar a um limiar de delimitação dos polígonos que fosse condizente com o objetivo de extrair áreas homogêneas da variação da resposta espectral dentro do talhão provocado pela irrigação. Esse processo requer um conhecimento prévio do objeto de estudo, áreas irrigadas, devido as particularidades do processo.

Foi seguido o exemplo de Jawak et al. (2015) que delimitaram e analisaram o processo de classificação orientado a objeto para agricultura, focando em áreas com alvos que representavam problemas na produção agrícola. Para identificar os alvos, foi criada amostras que direcionou uma análise dos problemas na cultura da cana. Foi testado centenas de parâmetros para encontrar o que mais se aproximava das variações consideráveis para delimitar o problema da má qualidade na fertirrigação.

Foi testado parâmetros fazendo um programa em *python* (3.5.4) importando as variáveis do algoritmo *Large Scale Mean Shift* (LSMS) do OTB para rodar de forma automatizada 125 testes com valores diferentes para segmentação.

3.2.7. Large Scale Mean Shift (LSMS)

Para gerar o modelo LSMS de classificação orientada ao objeto é necessário a execução de 4 etapas, sendo: *LSMS-MeanShiftSmoothing* (Etapa 1), *LSMS-Segmentation* (Etapa 2), *LSMS-SmallRegionsMerging* (Etapa 3) e o *LSMS-Vectorization* (Etapa 4). Em cada etapa é gerado um resultado que é utilizado como parte das entradas de dados da etapa seguinte. No que corresponde ao valor do produto de cada etapa, está descrito nos documentos do programa. A figura 19, apresenta o algoritmo de processamento.

O estudo feito por Fukunaga e Hostetler (1975) apresentou o algoritmo LSMS para segmentação de imagens VHR (*Very high resolution*), que exigiam muita capacidade de processamento. O trabalho resultou polígonos que representava uma imagem segmentada com variações de radiometria em cada banda e por ser um algoritmo desenvolvido para processar imagens com grande quantidade de bits (> que 1 gb), permite estabelecer a quantidade de memória ideal para processamento.

O processo de geração do LSMS é descrito a função das 4 etapas da seguinte forma:

- Etapa 1. Suavização:

No processo LSMS, avalia-se o processo de suavização adotando diferentes parâmetros de raio espacial para verificar o mais adequado.

O algoritmo oferece valores padrão do raio espacial, que dimensiona qual vai ser o alcance em distância para gerar os polígonos homogêneos. Testou-se combinações dos valores 5, com 10, 15, 20 e 30, para avaliar subdividindo de forma gradativa qual seria a resposta de cada parâmetro do algoritmo.

Por não haver mudanças nos segmentos nos alvos na imagem, optou-se para ir direto para etapa 2.

- Etapa 2. Segmentação:

Para ambos os arquivos de imagem (2018 e 2019) contendo as bandas R-G-B-NIR-Redige (1,2,3) -SWIR (1,2), foi realizado um processo de empilhamento de camadas para obter composição de nove bandas. Este passo foi necessário porque o OTB, no procedimento de segmentação, requer uma única imagem rasterizada como dados de entrada. Um recorte da imagem original foi feito de modo que apenas uma área menor de interesse, correspondente a área fertirrigada, foi classificada para encontrar o modelo (aproximadamente 60,85ha).

O processamento passou por vários testes até chegar em um limiar que se representa as variações correspondentes a quantidade e a forma de irrigação dos talhões. Esses processos foram executados em lote com parâmetros de segmentação. O programa em python (2014), foi feito um código com combinação dos 3 parâmetros alterando cada combinação de com intervalos de 20 (De 0 a 100) para *Spatial Radius* e intervalos de 200 para *range radius* e *minimum segment size* (De 0 a 1000). No total foram 125 combinações de segmentação diferentes. O código (Figura 20), foi construído para minerar o máximo de combinações e encontrar os valores mais adequados para segmentar a área de estudo.

O algoritmo LSMS tem como funções analisar o conjunto de informações na imagem no aspecto espectral e espacial. Na tabela 4, está descrito os parâmetros que melhor se adequaram ao estudo.

O algoritmo procura conjuntos locais de pixels similares baseado em $n+2$ dimensões, onde o n e o números de bandas espectrais que inseridas em duas dimensões espaciais. Neste contexto, o LSMS busca durante o processamento, pixels e identifica os que estão próximo no espaço espectral e também no espaço geográfico que correspondem as dimensões espaciais.

Os dois parâmetros que controlam o processo de segmentação. O raio espacial controla a distância (Alcance do número de pixel) que é considerado ao agrupar pixels em segmentos de

imagem. No entanto, a variável espacial ajuda controlar a elaboração do segmento, mas não é essa variável que define a criação do segmento, somente faz a varredura espacial (BONG, & RAJESWARI, 2011). O raio de alcance refere-se ao grau de variabilidade espectral, distancia nos espaços espectral, que corresponde a distância euclidiana, que determina a similaridade, espectral das medias do pixel entre as bandas (CARREIRA-PERPINÁN, 2015).

- Etapa 3. LSMS-SmallRegionsMerging:

O processo de validação dos segmentos gerados dentro do talhão é analisado com classificação dos objetos separados com os segmentos sobre a imagem. Neste trabalho, fui utilizado o programa QGIS 3.6.3 (2019), para abrir e analisar se o segmento tem relação com as variações internas do talhão e avaliado se está delimitando o objeto para classificar (Figura 24).

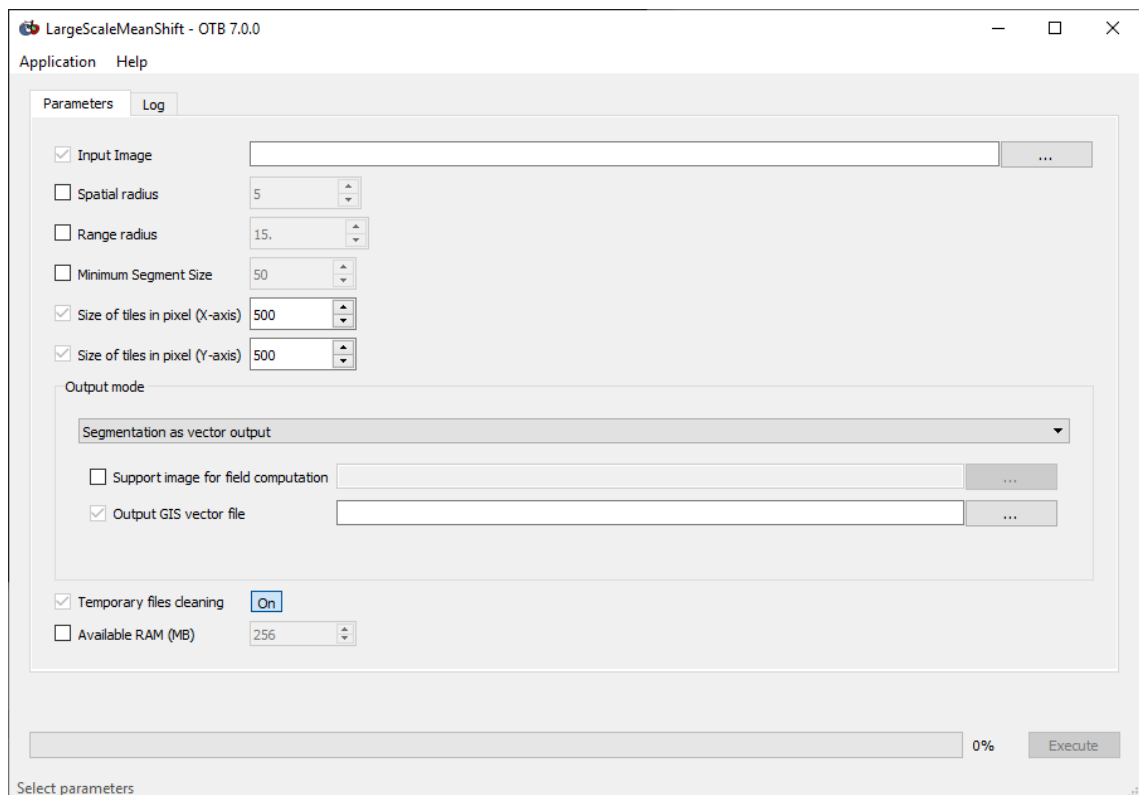


Figura 25 - Campos de processamento do LSMS. Fonte: o autor.

3.2.8. Medida de precisão

Para medir o desempenho das abordagens em comparação com os dados do mundo real, a precisão da classificação é calculada (LI, et al., 2014). Esta matriz compreende quatro

componentes: verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN) e falso negativo (FN). Em nosso caso, positivo significa uma classificação como irrigado, enquanto negativo significa uma classificação de qualquer outra classe. Desta forma, um objeto identificado como irrigado pelos agentes ou em a classificação baseada em objeto também é, na realidade, um objeto irrigado e contado como um VP. Por outro lado, se um objeto de qualquer outra classe é identificado, mas na realidade é agricultura irrigada, o resultado conta como um FN (VATSAVAI, 2013). Os parâmetros são apresentados na Tabela 4.

Os objetos estéreis também são contados como irrigado, porque a irrigação e as características específicas podem ser invisíveis após a semeadura ou colheita quando os lotes agrícolas são da produção.

A medida de precisão é usada exclusivamente para a comparação dos resultados e não influenciar os agentes nem os objetos de imagem. A precisão é calculada através do número de elementos que são identificados corretamente como a classe de destino, neste caso, irrigado, e o número verdadeiro total de objetos conhecido como irrigado.

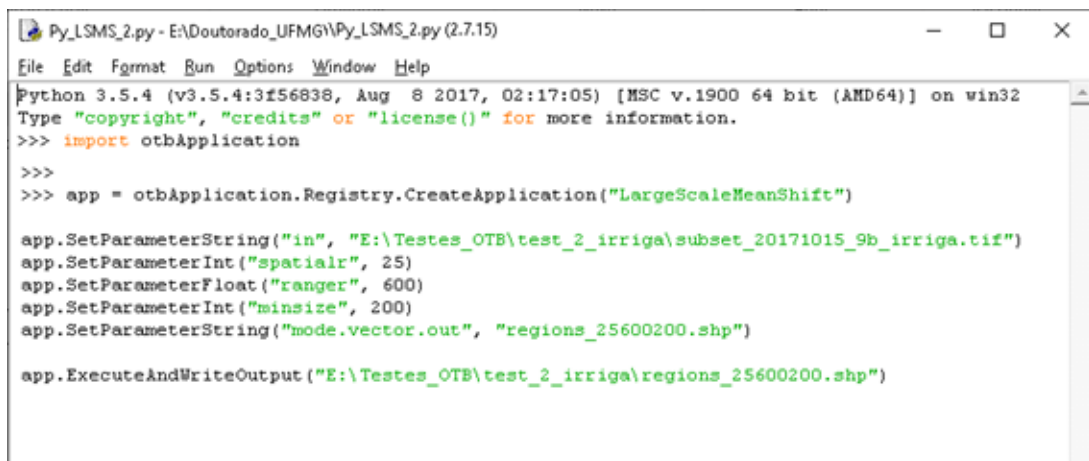
Tabela 5 - Parâmetros definidos após testes para chegar aos valores mais adequados para cana

Etapa	Parâmetros do LSMS padrão	Parâmetros definidos
LSMSSegmentation	Image input: smooth.tif output: segmentation.tif spatialr: 5 ranger: 15 minsize: 0 tilesizex: 256 tilesizey: 256	spatialr: 80 - 60 ranger: 15 - 15 minsize: 100 - 50

Para manter os resultados comparáveis, todos os objetos são dissolvidos em pixels, o que significa que o número total N de todos os elementos permanece o mesmo para todas as abordagens. Por exemplo, AccVP, conforme equação descreve a precisão de sistemas irrigados identificados corretamente, sendo objetos: N_p , o número de objetos identificados corretamente como irrigado, dividido pelo número verdadeiro de objetos irrigados N_{kp} . Esta medida de precisão também é calculada para os casos VN, FP e FN (MEWES & SCHUMANN, 2019).

$$ACC_{TP} = \frac{N_p}{N_{KP}}$$

Para avaliação da precisão na classificação, a qualidade da classificação é avaliada quantitativamente por meio dos coeficientes de precisão global (GA) e Kappa (κ), ambos extraídos de a matriz de confusão (CONGALTON & GREEN, 2009).



```

Py_LSMS_2.py - E:\Doutorado_UFMG\Py_LSMS_2.py (2.7.15)
File Edit Format Run Options Window Help
Python 3.5.4 (v3.5.4:3f56838, Aug 8 2017, 02:17:05) [MSC v.1900 64 bit (AMD64)] on win32
Type "copyright", "credits" or "license()" for more information.
>>> import otbApplication
>>>
>>> app = otbApplication.Registry.CreateApplication("LargeScaleMeanShift")
app.SetParameterString("in", "E:\Testes_OTB\test_2_irriga\subset_20171015_9b_irriga.tif")
app.SetParameterInt("spatialr", 25)
app.SetParameterFloat("ranger", 600)
app.SetParameterInt("minsize", 200)
app.SetParameterString("mode.vector.out", "regions_25600200.shp")
app.ExecuteAndWriteOutput("E:\Testes_OTB\test_2_irriga\regions_25600200.shp")

```

Figura 26 - Código para análise em mineração para encontrar melhor combinação para o modelo de segmentação para áreas fertirrigação com *cana-de-açúcar*. Fonte: o autor.

4. RESULTADOS

São apresentados os resultados parciais obtidos nos estudos na área amostral, que servirão de base para se replicar o estudo em área mais ampla na próxima etapa de investigação.

4.1. Avaliação dos entre diferentes sensores no monitoramento da fertirrigação

A correlação de Pearson entre a tonelagem de cana-de-açúcar por hectare (STH 2018), o número de colheita (NH 2019) e as faixas individuais de três datas de imagem S-2 são mostradas na Tabela 5.

Existe correlação de acordo com o método Pearson entre a tonelada por hectare e o número de colheitas com os índices NDWI e SAVI das imagens S-2 e com as polarizações das imagens S-1. Em geral, o índice NDWI respondeu melhor do que o SAVI em termos de

significância, mas o SAVI obteve correlações mais fortes, especialmente para a imagem de abril de 2018, que corresponde à cana principalmente madura. Isso é verdadeiro para TCH e NC.

As correlações positivas entre TCH e SAVI mostram que a produtividade pode ser estimada por meio do índice de vegetação, enquanto a correlação negativa entre NH e SAVI significa que a produtividade diminui significativamente à medida que o número de colheitas aumenta. As correlações positivas entre NH e SAVI em datas anteriores (julho e agosto) estão principalmente relacionadas ao fato de que muitos campos foram colhidos e, portanto, estão com muita pouca massa verde. As correlações negativas das datas anteriores podem estar provavelmente relacionadas ao mesmo fator dos talhões da data de colheita.

A imagem (abril de 2018) mostrou correlação significativa (acima de 0,2 ou abaixo de -0,2) com TCH ou NC. Isso foi atribuído ao fato de que muitos campos ainda não foram colhidos e, portanto, são o resultado da aplicação de fertirrigação do ano anterior (2017). A segunda imagem mostrou algumas correlações significativas (embora apenas na ordem de -0,20 a -0,27) nas bandas do visível, infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR). Embora todos os talhões provavelmente tenham sido colhidos, o fato de o crescimento variar significativamente entre os campos pode mascarar parcialmente o efeito procurado.

Finalmente, a imagem de abril de 2019 mostra três correlações moderadamente fortes (0,4) entre TCH e duas bandas de borda vermelha e uma banda NIR. Curiosamente, todas as faixas podem ser significativamente correlacionadas ao número de safras e isso é causado diretamente pelo fato de que a produtividade dos campos cai cerca de 10% a cada safra adicional, porém se o processo de fertirrigação for aplicado adequadamente.

Tabela 6 - Resultados da correlação de Pearson entre a tonelagem por hectare (TCH), o número de colheita (NH) e os índices SAVI e NDWI.

Correlação de Pearson						
S-2 Image	TCH				Número de colheita	
	TCH-NDWI		TCH-SAVI		NC-NDWI	NC-SAVI
04-04-2018	-0.04		0.11		-0.04	0.11
12-07-2018	-0.17		-0.17		-0.17	0.37
01-08-2018	-0.20**		-0.28*		-.0.20**	0.33**
30/09/2018	-0.05		0.08		-0.05	0.13
09/11/2018	0.31**		0.36**		0.31	-0.11
18/04/2019	0.16		0.56**		0.16	-0.73**
S-1 Image	VV		VH		VV / VH	
	TCH	NC	TCH	NC	TCH	NC
07-09-2018	0.20**	-0.17**	0.04	0.12**	0.22**	-0.34**
23-04-2019	0.19**	-0.36**	0.11**	-0.20**	0.15**	-0.32**

Os números em negrito estão todos acima de 0,2 ou abaixo de -0,2. * significante a 95% ** significativo a 99%

A Tabela 6 mostra o resultado da análise de variância (ANOVA) realizada para testar a hipótese alternativa H1 que o grupo de campos com estresse nutricional (espalhamento parcial desigual da vinhaça) é caracterizado por diferentes meios de valores de SAVI e NDWI.

Descobriu-se que apenas duas das seis datas de imagem (setembro de 2018 e abril de 2019) permitiram rejeitar o H0 de que os dois grupos têm médias de NDWI diferentes e apenas em 95% ($p < 0,5$); e apenas uma imagem (set. 2018) para o SAVI.

Tabela 7 - Análise de variância entre talhões visualmente identificados para mostrar problemas de fertirrigação e talhões sem problemas. Os índices SAVI e NDWI foram analisados individualmente para as seis datas diferentes da imagem S-2

S-2 Image Date	NDWI		SAVI	
	F-test	Sig.(p)	F-test	Sig.(p)
04-04-2018	1.42	0.24	1.74	0.19
12-07-2018	0.43	0.51	0.29	0.59
01-08-2018	0.38	0.54	0.80	0.37
30/09/2018	4.58	0.036*	4.44	0.038*
09/11/2018	2.28	0.14	3.23	0.08
18/04/2019	4.12	0.046*	3.47	0.07

O conhecimento das fazendas com problemas conhecidos que apresentavam mais contraste, após processamento dos índices de vegetação, foi verificado que o SAVI (índice de vegetação ajustado ao solo) e o NDWI (índice de diferença de água normalizado), mostravam maior discriminação quando porções dos talhões não receberam a mesma quantidade de vinhaça.

4.1.1. Conclusão da correlação entregue número de corte e resposta espectral

O estresse de nutrientes nas plantações causado pela pulverização irregular ou parcial de vinhaça em culturas de cana-de-açúcar é facilmente visível nas imagens do Sentinel, especialmente nas imagens ópticas S-2. Porém, o fato de a colheita se estender por um longo período dificulta o monitoramento sistemático. Outras variáveis, como o número de colheitas, podem mascarar facilmente o problema em um sentido estritamente radiométrico médio (sobre campos). Parece que o que é visualmente perceptível é, na verdade, o resultado de uma interpretação avançada que envolve não apenas o tom ou a cor, mas também a forma, o tamanho, o contexto e a dimensão do tempo.

Neste estudo, uma dificuldade adicional veio do fato de que para esta indústria a produtividade é medida em uma base de fazenda ao invés de em cada campo que também contribui para mascarar os problemas de fertirrigação em talhões individuais.

Apesar dessas considerações, encontramos uma série de observações dignas de nota em nossos resultados: 1) Sentinel-2 (ótico) é claramente superior ao Sentinel-1 (SAR) para identificar problemas de fertirrigação, mas este último ainda deve ser considerado para períodos nublados; 2) os índices SAVI e NDWI são superiores às bandas individuais que só permitirão a identificação de problemas de fertirrigação em conjunto, enquanto os índices capturam esses efeitos isoladamente; 3) as imagens correspondentes ao final da estação (pouco antes do início da colheita) são geralmente melhores para identificar os problemas de fertirrigação que, por sua vez, são tardios demais para serem solucionados; 4) outros fenômenos como preparo do solo, pragas, plantas invasoras, replantio parcial podem interferir diretamente na identificação de problemas de fertirrigação.

Sugerimos que a primeira modificação no processo de coleta de dados deve ser um controle baseado em campo para poder monitorar campos com base em suas respectivas datas de colheita.

4.1.2. Avaliação comparativa entre as médias de dados SR e de campo dos anos subsequentes

As primeiras análises das correlações seguiram de 2019 a 2021 considerando as médias não apenas entre valores dos dados de imagens por satélite (SAVI e NDWI), o segundo modelo de correlação, foi considerado novos dados de colheita e de imagens. Para as imagens optou-se em extrair os índices, NDVI e NDWI. Os dados de campo, foram considerados além do número de corte (Quantidade de colheita) os dados de TCH e ATR (kg/açúcar por tonelada de cana).

Com teste de normalidade dos dados, foi observado e aceito a distribuição dos dados como normal (Figura 26).

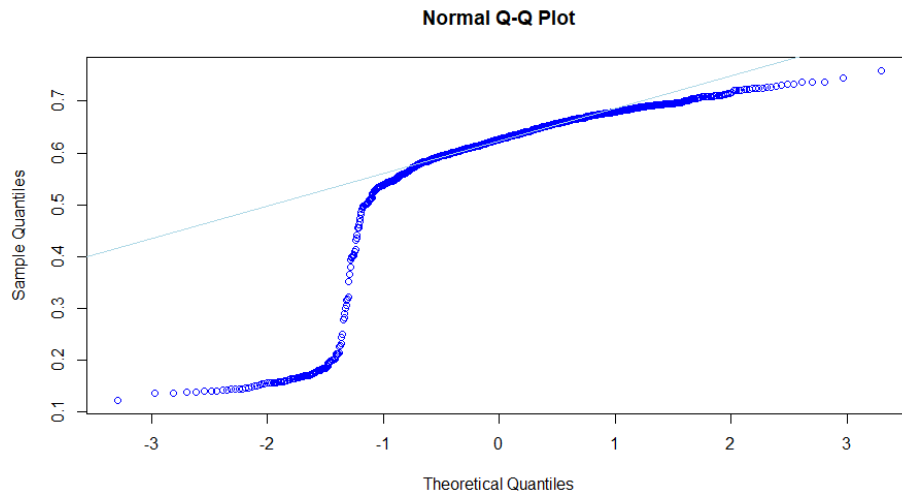


Figura 27-Gráfico de representação da distribuição dos valores do índice de vegetação para mês de abril de 2021
Fonte: o autor.

A correção de Pearson apresentou $t = 3.5954$, $df = 730$, $p\text{-value} = 0.0003457$, ou seja, com o valor de p muito abaixo de $0,05$ e aceita a correlação.

O modelo de regressão múltipla apresentou a correlação de distribuição normal para os dados de NDVI/NDWI (Datas: 04/2018 – 04/2019 – 04/2020 – 04/2021) no pico máximo de crescimento da cana e no período pré-colheita e os dados de campo (Figura 27).

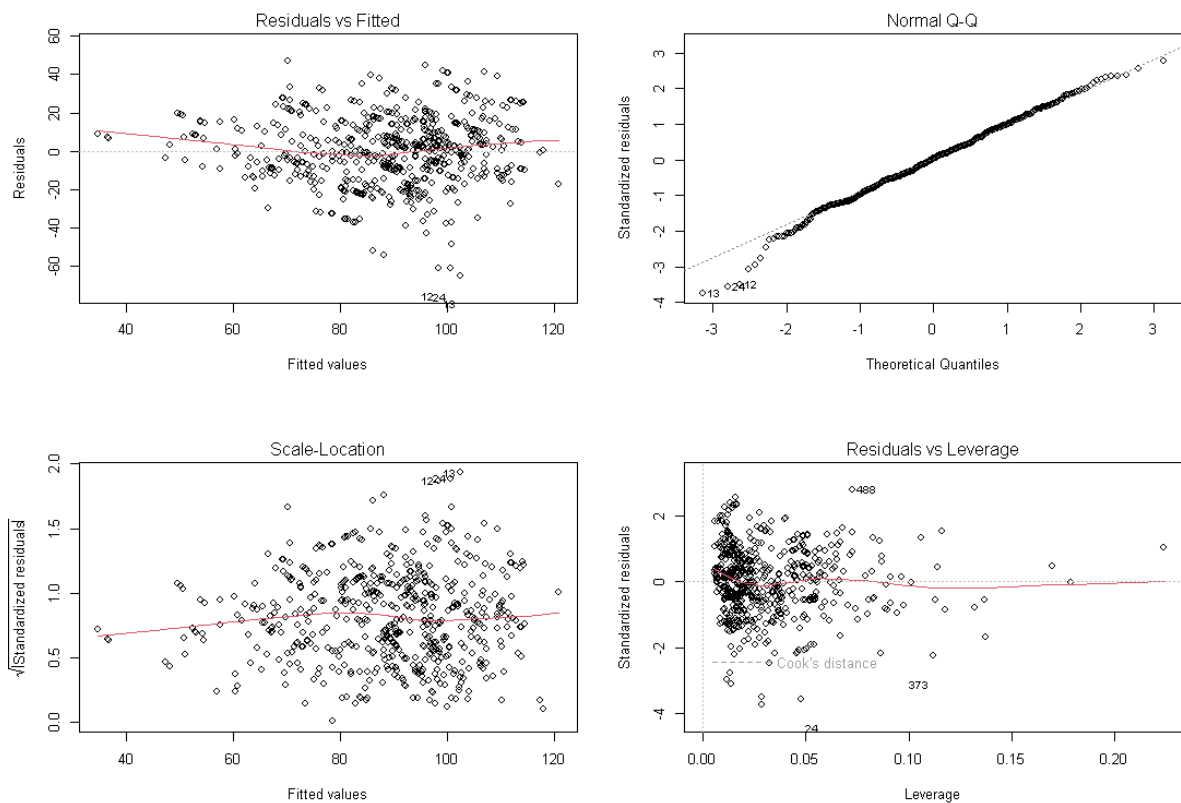


Figura 28. Gráficos representando a regressão múltipla para todas as amostras e correção normal (Normal Q-Q) com a linha vermelha acompanhando a linha central de referência das avaliações residuais complementares.

Fonte: ao autor.

O resultado para a regressão ficou em F-estatística: 23.14 em 17 e 560 graus de liberdade p -: $< 2.2e-16$. Com R^2 0,51, o que é para dados ambientais é considerável.

Como os dados apresentaram correlação, analisados de estatística forma isolada, foi avaliado somente as médias para cada valor, condensando mais de 600 amostras. A figura 28 apresenta os resultados de correlação das médias.

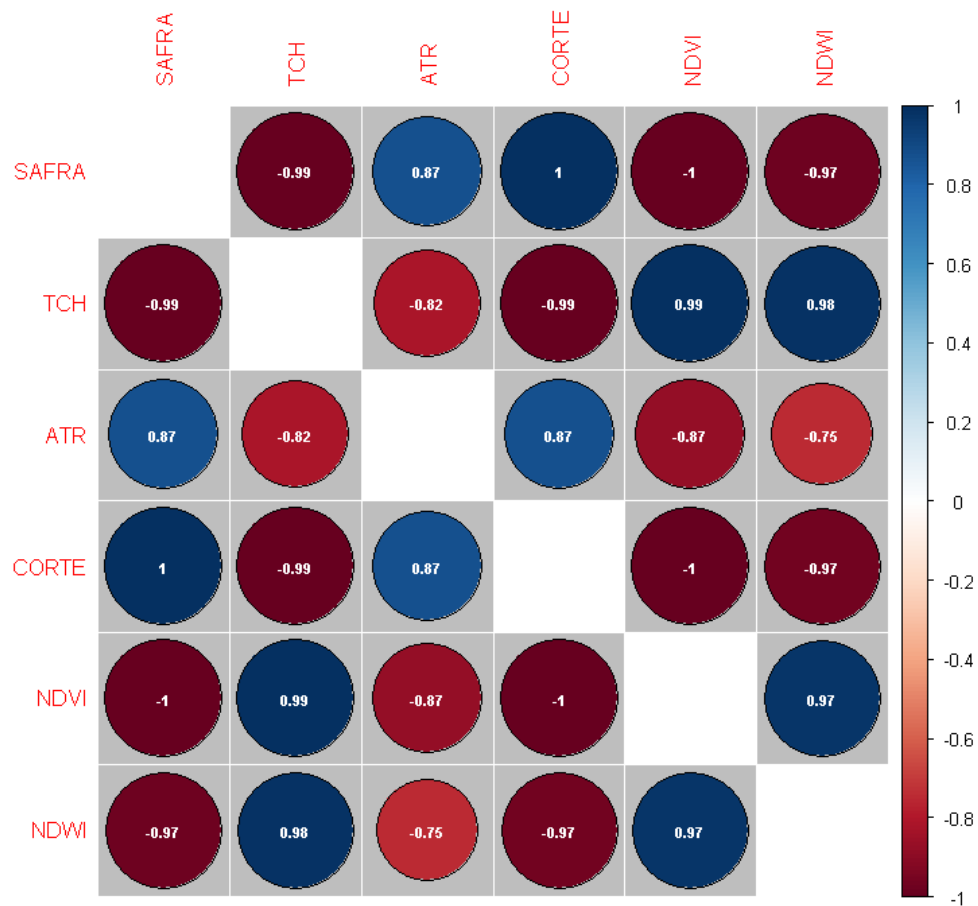


Figura 29. Correlação de Pearson (Escala de valores de p) para médias das safras 2018, 2019, 2020, 2021. Significante a 95% ** significativo a 99%. Fonte: o autor.

Todas as correções das médias tiveram correlação alta correlação positiva e negativa, apresentando que os valores de sensoriamento remoto acompanham a perda de TCH com a sequência de colheita de uma safra para outra.

4.1.3. Comparação dos valores de índice de água (NDWI) para reamostragem bilinear e vizinho mais próximo

A comparação foi em torno das médias dos valores do índice de água por diferença de normalizada, que foi utilizada para gerar as correlações estatísticas. Observe a estatísticas figura 29, que apresenta de forma visual a diferença das duas imagens que apresentam os índices.




Figura 30. Diferença entre reamostragem vizinho mais próximo (VP) (A) e bilinear (B). Fonte: o autor.

O processamento da imagem no método bilinear (B) a imagem aparece em um aspecto mais embasado visualmente, com linhas mais suaves, sem o formato serrilhado conforme apresenta a imagem do vizinho mais próximo (A). Na reamostragem bilinear o algoritmo utiliza os 9 pixels no entorno para processar e no vizinho mais próximo utiliza 4. Foi calculado as médias para de cada talhão e para a variação não foi significativa, NDWI 0,4710 (VP) e NDWI 0,4706 (Bilinear).

4.2. Classificação orientado a objeto aplicado no monitoramento da fertirrigação.

A foto tirada por um drone demonstra a mancha deixada, claramente, na superfície no formato de 180 graus pela irrigação (Figura 30). Conforme apresentado e verificado na imagem de satélite, houve manchas variadas deixadas pelo modo como procedimento foi executado em campo. Esse é o resultado de um manejo sem controle necessário, devido a vários fatores, como regulação no tempo de recolhimento e pressão da bomba.

Foi possível identificar e mapear as falhas de fertirrigação s com as imagens. Como observado na imagem, às machas da fertirrigação com vinhaça são visíveis, desde que o operador conheça o processo de manejo, mas algumas variações são suaves para análise visual, mas para o classificador foi passível de separação. Dentro desse processo o desafio foi observar

os dados de imagens para extrair as variações das manchas de irrigação, segmentar e classificar de forma automatizada. Assim, o resultado é um processo de manejo que possibilita correção do manejo e aumento de produtividade.

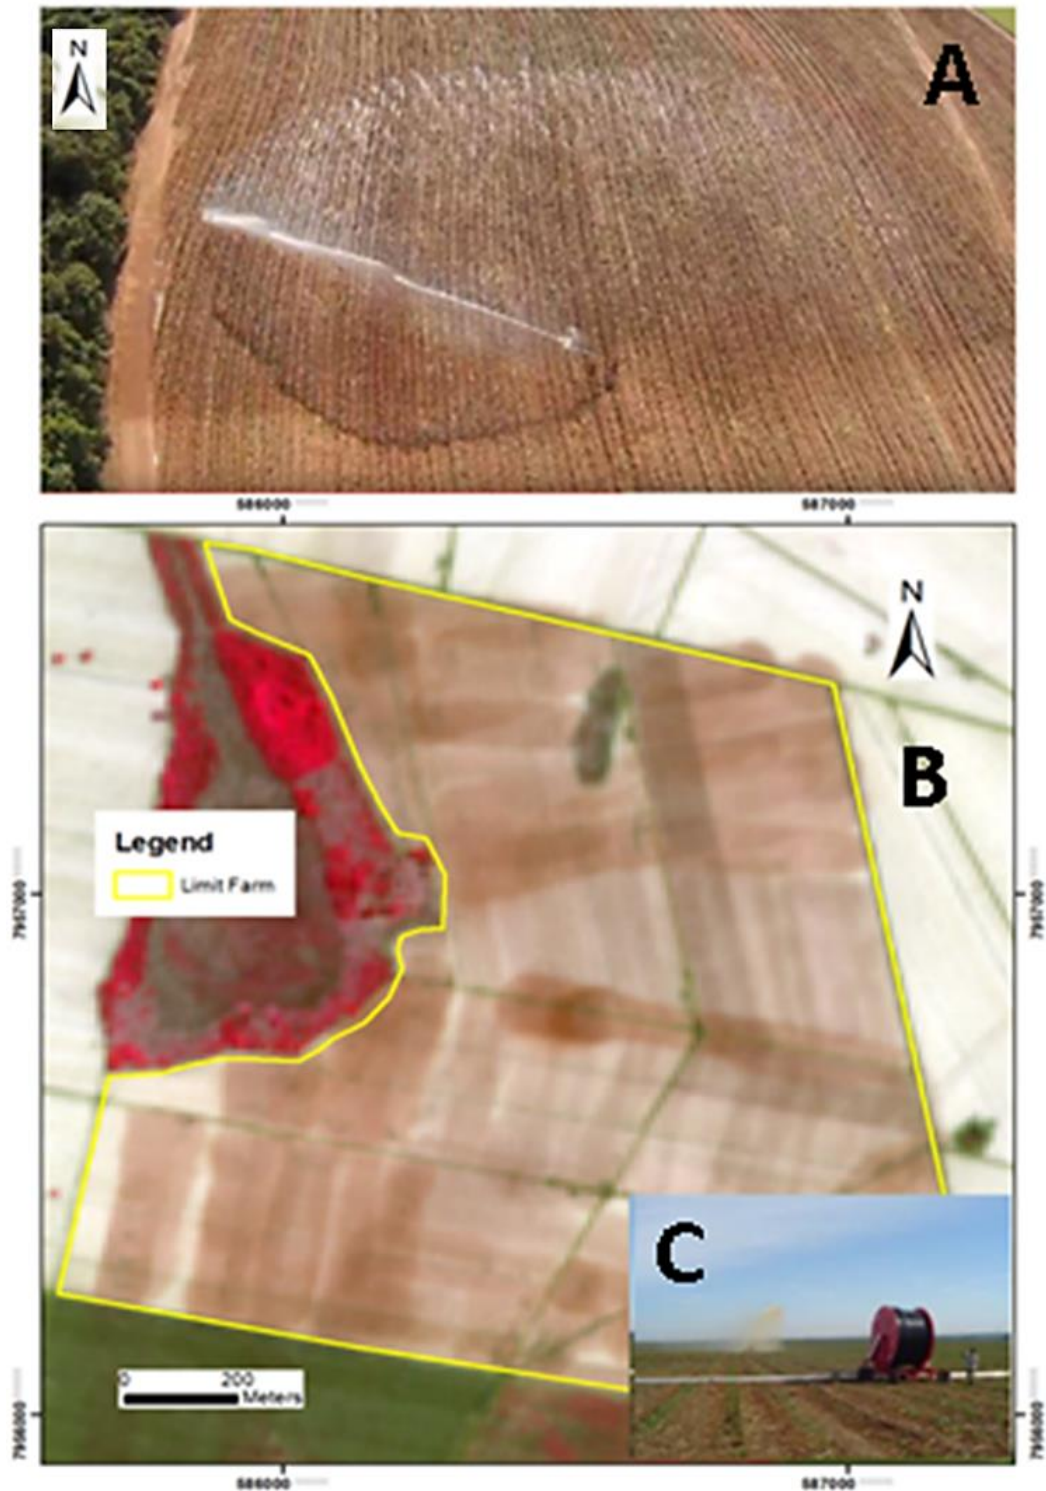


Figura 31 - Foto tirada por drone no momento da irrigação com sistema de recolhimento automático com a seta mostrando o sentido da foto (a). Imagem de satélite Sentinel 2A, composição R8 G4 B3 com a indicação do local da irrigação (b). Foto atrás do sistema de fertirrigação com carretel hidro-roll de 350m (c). Fonte: o autor.

Como a atividade de fertirrigação é realizada alguns dias após a colheita, sobre a palha que tem uma cor clara, a vinhaça que tem uma cor escura marca sobre a palha onde o produto foi lançado, também mostra a variação no recolhimento (Figura 31).

O processo deve seguir como forma de manejo uma pressão mínima para que tenha a eficiência necessária e isso depende dos motores da motobomba na rotação correta, o rolo carretel recolhido no tempo correto e a quantidade de vinhaça no canal ou tanque estar na quantidade mínima para as motobomba fazer a sucção na quantidade ideal. Se alguma regulagem falhar, iria refletir na quantidade lançada em campo.

O processo de classificação orientado a objeto, com mais de uma centena de testes combinatórios de segmentação, resultou em duas combinações de parâmetros que separou e identificou as variações no processo de irrigação das fazendas pós-colheita. A combinação que mais detalhou as variações de manchas na aplicação vinhaça com maior precisão está representada na Figura 32.

Os parâmetros definidos para classificar orientado a objeto as feições de fertirrigação estão apresentados (Tabela 7).

Tabela 8 - Parâmetros de maior detalhamento da variabilidade no manejo de irrigação com vinhaça.

Parâmetros	Valores
Raio espacial	5
Intervalo do raio	200
Tamanho mínimo	50

A segmentação separou detalhes nas aplicações de vinhaça de forma suficiente para realizar a classificação orientada a objeto. Todos os polígonos delimitados representam que houve variação quantitativa durante a aplicação, reflete que a operação não está sendo eficiente.

Os resultados da segmentação evidenciam uma avaliação qualitativa, mesmo que as manchas representem uma variação quantitativa em campo, pois para uma avaliação quantitativa seria necessário ter os dados precisos do volume aplicado durante o processo.

A distribuição das amostras dentro das fazendas (Figura 33) requer um cuidado no momento da seleção, pois se uma quantidade ficar muito maior que as demais o classificador

gera resultados que não representa uma realidade das manchas e classifica inadequadamente. Essa afirmação é possível devidas dezenas de testes amostrais. Os valores de refletância do alvo, derivado da mistura de vinhaça, palha e solo, determinam os valores das médias das manchas, que são intervalos curto de uma mancha para outro, ou seja, com uma variação espectral leve.

Os valores de média e a forma visual foram aplicados para analisar a variação da amostragem dentro da fazenda. É importante que seja verificado usando diferentes tipos de realce e combinações para que na análise visual seja feito de forma mais precisa. Além das combinações em falsa cor tradicional as imagens Sentinel tem uma combinação sugerida própria para agricultura que facilitou a análise das manchas, bandas 8, 12 e 3.




Figura 32 - Representação dos parâmetros que melhor separou a variabilidade na aplicação de vinhaça no sistema LSMS.




Figura 33 - Distribuição da amostragem para classificação orientada a objeto.

A definição visual e pelas médias identificou a quantidade de 5 classes. O modelo gerado pelo OTB classificou as áreas mais homogêneas de distribuição da irrigação, apresentando onde foi pouco e muito irrigado. A Figura 33 apresenta a classificação orientada a objeto.

Essa análise resultou um processo de monitoramento, que garante eficiência no processo produtivo e ambiental, fornecendo segurança na garantia de produção de cana e pressiona a operação exercer a atividade correta, seguindo as normativas ambientais, para que não tenha risco de aplicação em copos hídricos e áreas de preservação permanente.

O sensoriamento remoto por satélite garantiu com essa análise um baixo custo e uma velocidade de revisita maior quando comparado com o a forma manual, indo a campo e medindo de forma amostral e comparado com voo por drone.

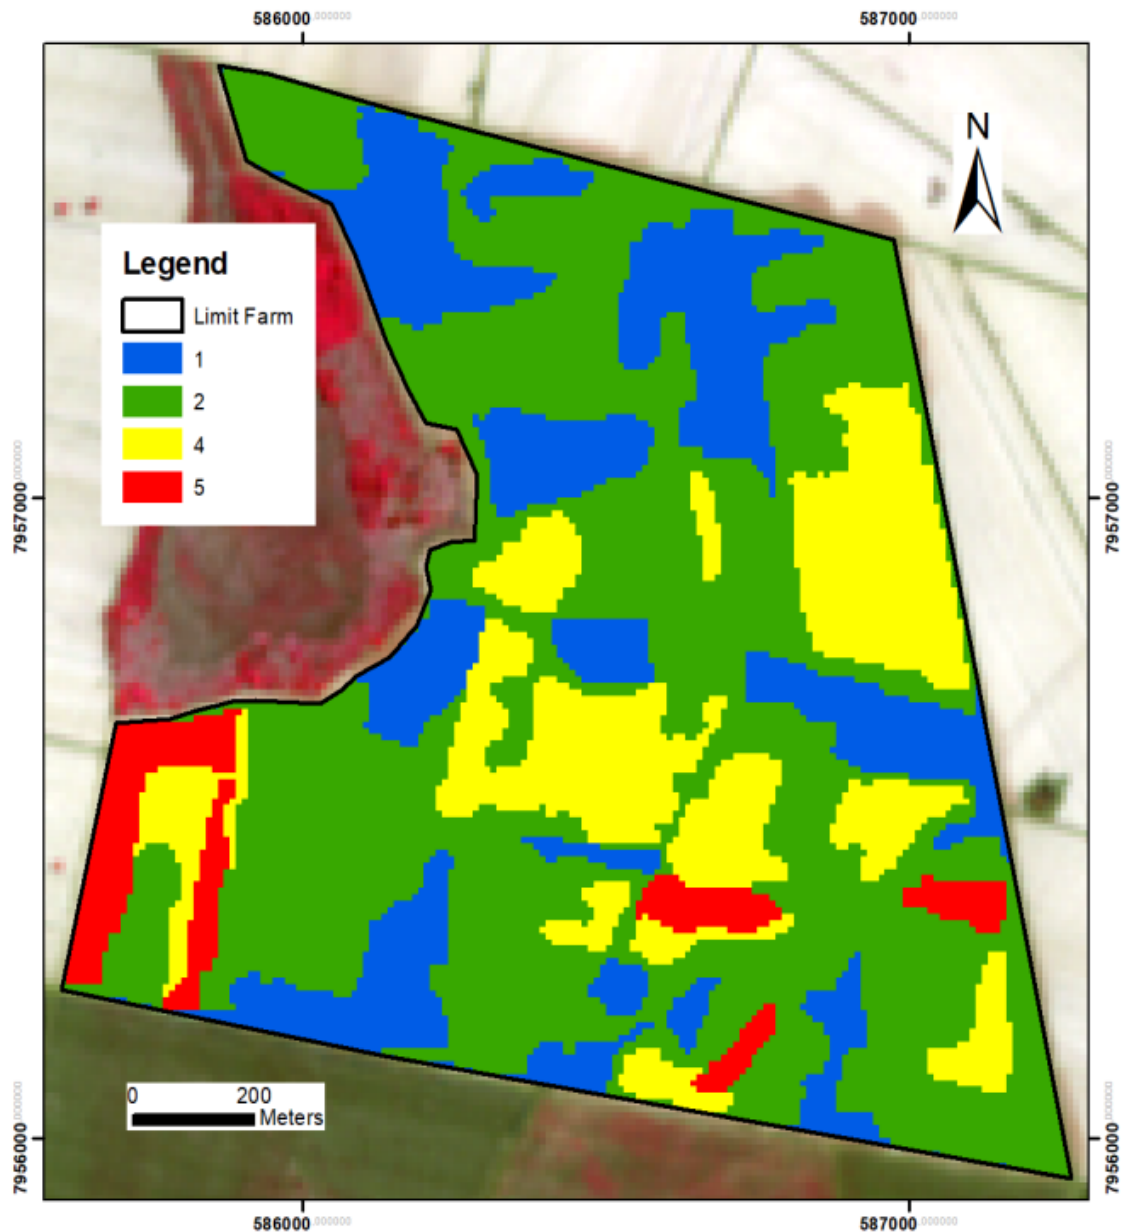


Figura 34 - Classificação orientada a objeto baseado no modelo gerado no OTB. Variação nível (1); Variação nível (2); Variação nível (3); Variação nível (4); Zona sem fertirrigação (5).

De forma manual, não tem eficiência para verificar grande área, hidrante por hidrante e com Drone, o custo seria muito alto, com o custo atualmente em 15 reais por hectare, em 20 mil hectares da área de estudo, custaria 300 mil reais por levantamento ano. Como as imagens de satélite são de domínio público, Sentinel (ESA), Landsat (NASA) e CBERS (INPE) além de outros satélites que tem possibilidade de serem aplicados, o custo é somente de mão de obra especializada.

5. CONCLUSÃO

O trabalho teve duas linhas de trabalho que são correlacionadas, a primeira: analisou a correlação de dados de sensoriamento remoto com a produtividade. A segunda: analisou a capacidade de identificação e classificação das áreas de manejo de irrigação por sistema utilizando vinhaça, denominado fertirrigação. Contudo, a qualidade do manejo na fertirrigação tem relação direta na produtividade, uma vez que em área que receber vinhaça, não é feita a adubação tradicional, por ser a vinhaça a irrigação e a adubação ao mesmo tempo.

O monitoramento do processo da fertirrigação, através da observação da localização da aplicação, ou seja, se seguiu o manejo com o posicionamento correto dos implementos que lançam a vinhaça, se houve falta ou excesso, as imagens de satélite registraram de forma a permitir a identificação por segmentação e classificação orientado ao objeto.

O modelo de classificação utilizado, através do OTB (*Orfeo ToolBox*), foi aplicado de forma satisfatória nas imagens de satélite para identificação dos locais de fertirrigação. Os testes de combinação de valores para encontrar a melhor combinação para identificação dessas áreas é relativamente demorado, considerando um computador desktop de uso residencial. No total foram gastos aproximadamente 80 horas de processamento contínuo realizar todas as combinações até encontrar uma que fosse adequada.

Além da identificação das áreas de falhas (zonas que não foram fertirrigadas) o processo de classificação permitiu a identificação na variação quantitativa, ou seja, das zonas que receberam quantidade variada de vinhaça devido à falta de calibração dos sistemas agrícolas que realizam a aplicação.

Após a definição da melhor combinação para segregação da área do alvo estudo, o sistema permitiu criar um modelo baseado nos valores espectrais do alvo e aplicar em qualquer outra imagem. Essa etapa permitiu criar um modelo e monitorar a qualidade do manejo na aplicação de fertirrigação.

Na pesquisa para se encontrar uma correlação entre a produtividade, na primeira etapa, optou-se por selecionar imagens ao longo dos anos, entre 2017 e 2019. As respostas de correlação aconteceram em apenas algumas imagens, nas datas onde o estágio de crescimento da cana estava maior. Nessa etapa, foi considerado o número de corte (Colheita), o TCH (Toneladas por hectares) e índices de vegetação. Assim, foi identificado que existe uma correlação entre o número de colheitas, produtividade e a mudança nos valores de resposta dos índices.

Para as imagens de 2019 a 2021, optou-se para uma maior precisão, usar a correlação de índices com os dados de produtividade, somente com as imagens do mês de abriu para cada ano safra. Houve correlação na regressão dos dados de cada talhão e na distribuição das médias mais preciso e alimentou a correlação dos dados.

A base para um modelo de estimativa de produtividade para a cana-de-açúcar tem efeito direto na reposta por satélite, indicando que pode haver um modelo para estabelecer produtividade por SR que será mais preciso e efetivo que o modelo usado atualmente pelo mercado, que é por inspeção visual em campo.

Os estudos dos efeitos da variabilidade na aplicação da vinha em relação à produtividade não foram realizados neste trabalho. Porém, como foi mapeado o modelo de classificação e a relação de índices com produtividade, os estudos já realizados abrem caminho para estudos futuros para essa aplicação.

O campo da agricultura, tem relação direta com a Geografia, pois depende do contexto geográfico para ocupar um território e realizar práticas de produção. Ocupar e expandir em territórios significa compreender a dinâmica e as variações que ocorrem para planejamento e tomada de decisão. Além do fator do SR permitir monitoramento em grandes áreas com custo baixo e precisão, traz uma ferramenta de solução para um dos maiores desafios da agricultura, produzir mais na mesma área.

Após os testes e análises realizadas, o resultado do trabalho é um produto aplicado no manejo de controle e monitoramento da qualidade da aplicação da fertirrigação na produção de cana. O que pode ser evoluído é automatização do processo, mas os passos para executar o processo foi evidenciado como ferramenta aplicada.

O sensoriamento remoto por satélite tem investimentos garantidos pelos próximos anos pelas agências espaciais de vários pais e fornecendo imagens de forma aberta, isso garante pelo menos mais 10 anos de dados de imagem e com a perspectiva de novos satélites com melhor resolução público.

Os produtos gerados têm a capacidade de ser aplicado em grande e pequenos produtores, com a capacidade de garantir e melhorar a produção.

O trabalho deixou algumas lacunas a serem desenvolvidas em estudos futuros e complementares, com avaliar o quanto a variabilidade da fertirrigação interfere na produtividade. A classificação com redes neurais será o próximo passo para se avaliar qual o melhor modelo para classificação, assim como o emprego de uma possível correção de satélite com dados de drone.

6. REFERÊNCIAS

- ABDEL-RAHMAN, E. M., & Ahmed, F. B. **The application of remote sensing techniques to sugarcane (*Saccharum spp. hybrid*) production: a review of the literature.** *International Journal of Remote Sensing*, 29, 13, 3753-3767, 2008.
- AL-ABBAS, A.H., BARR, R., HALL, J.D., CRANE, F.L. and BAUMGARDNER, M.F. **Spectra of normal and nutrient deficient maize leaves.** *Agronomy Journal*, 66, 4, 16–20, 1974.
- ALVES, L. Q.; FRANCO, P. N.; ZANETTI, W. A. L.; GÓES, B. C. **PERFORMANCE OF SUGARCANE CULTURE PRODUCTION IN THE MAIN PRODUCING STATES.** *Revista Brasileira de Engenharia de Biosistemas*, Tupã, São Paulo, Brazil, v. 15, n. 2, p. 303–317, 2021.
- ALBORNOZ, C.; GIRALDO, L.F. **Trajectory design for efficient crop irrigation with a UAV.** In *Proceedings of the 2017 IEEE 3rd Colombian Conference on Automatic Control (CCAC)*, Cartagena, Colombia, 18–20, 2017.
- ALMEIDA, T.I.R., DE SOUZA FILHO, C.R. and ROSSETTO, R. **ASTER and Landsat ETM + images applied to sugarcane yield forecast.** *International Journal of Remote Sensing*, 27, pp. 4057–4069, 2006.
- ANZILIERO, D. **As Técnicas de Monitoramento por DRONE: Uma Revisão dos Resultados Obtidos na Agricultura.** *Epitaya E-Books*, 1(10), 34-47, 2021.
- AKÇAY, H. G., AKSOY, S. **Automatic detection of geospatial objects using multiple hierarchical segmentations.** *IEEE Transactions on Geoscience and Remote Sensing*, 46(7), 2097-2111, 2008.
- ARVOR, D., et al. **Advances in geographic object-based image analysis with ontologies: A review of main contributions and limitations from a remote sensing perspective.** *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 125-137, 2013.
- ARC, 2000a. **Evaluation of NAOAA-AVHRR satellite information for the estimation of sugarcane yields at a macro scale.** *Agricultural Research Council Report No. Pretoria, South Africa*, 11, 34, 236-249, 2000.
- ARC, 2000b, **Evaluation of aerial remote sensing using a digital multispectral video sensor (DMSV) for field monitoring and management of sugarcane.** *Agricultural Research Council Report No. Pretoria, South Africa*, 12, 35, 123-136, 2000.
- AUDE, M. I. da S. **Estádios de desenvolvimento da cana-de-açúcar e suas relações com a produtividade.** *Ciência Rural*, Santa Maria: Universidade Federal de Santa Maria - UFSM, Centro de Ciências Rurais, v. 23, n. 2, p. 241-248, 1993.
- APAN, A., HELD, A., PHINN, S. and MARKLEY, J. **Spectral discrimination And classification of sugarcane varieties using EO-1 Hyperion hyperspectral imagery.** In *Proceedings of the 25th Asian Conference on Remote Sensing*, 22–26, 2004

BAUER, M.E.; CIPRA, J.E. **Identification of Agricultural Crops by Computer**. Processing of ERTS MSS Data; LARSTechnical Reports; Purdue University: West Lafayette, IN, USA, p. 20. 1973.

BAUER, M. E., CIPRA, J. E., Anuta, P. E., & Etheridge, J. B. **Identification and area estimation of agricultural crops by computer classification of Landsat MSS data**. Remote Sensing of Environment, 8(1), 77-92, 1979.

BAH, M.D.; Hafiane, A.; CANALS, R. **Weeds detection in UAV imagery using SLIC and the hough transform**. In Proceedings of the 2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA), Montreal, QC, Canada, 28, pp. 1–6, 2017.

BALASTREIRE, L. A. **A Estado-da-Arte da Agricultura de Precisão no Brasil**. 1. ed. Piracicaba: L.A. Balastreire, v. 1, 224, 2000.

BASSOI, L., et al. **Agricultura de precisão: resultados de um novo olhar**. Embrapa, 2014.

BENZ, U.C., et al. **Multi-resolution,object-oriented fuzzy analysis of remote sensing data for GIS-ready information**. ISPRS Journal of Photogrammetry & Remote Sensing 58, pp. 239-258, 2004.

BÉGUÉ , A., et al. **Application of remote sensing technology to monitor sugarcane cutting and planting in Guadeloupe (French West Indies)**. In International Congress Geomatica, 10–14, La Havane, Cuba, 2004. Available online at: http://publications.cirad.fr/une_notice.php?dk5521009 (acessado, 22 de janeiro de 2022).

BENJAMIN, Mewes. ANDREAS, Schumann. **An agent-based extension for object-based image analysis for the delineation of irrigated agriculture from remote sensing data**, International Journal of Remote Sensing, 4, 56, 78-82, 2019.

BHERING, S. B. **Influência do manejo do solo e da dinâmica da água no sistema de produção do tomate de mesa: subsídios a sustentabilidade agrícola do Noroeste Fluminense**. 2007, Tese, UFRJ/Programa de Pós-Graduação em Geografia.

BLASCHKE, T., et al. **Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications**. Environmental information for planning, politics and the public, 2, 555-570, 2000.

BNDES In: **BNDES 60 anos: perspectivas setoriais**. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, p. 62-87, 2012.

BONG, C. W., RAJESWARI, M. **Multi-objective nature-inspired clustering and classification techniques for image segmentation**. Applied soft computing, 11(4), 3271-3282, 2011.

BRAGA, D. L., et al. **Crescimento da cana-de-açúcar (1ª soca) sob diferentes níveis de fertirrigação potássica**. In Embrapa Meio-Norte-Artigo em anais de congresso (ALICE). In: CONGRESSO NACIONAL DE IRRIGAÇÃO E DRENAGEM, 21, Petrolina, 2011.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Portaria nº 852 - Art. 1º Criar a Comissão Brasileira de Agricultura de Precisão – CBAP**. Diário Oficial da República Federativa do Brasil, Brasília, DF, 21 set. 2012. Seção 1, n. 184. Disponível em: <http://www.cnpt.embrapa.br/biblio/do/p_do42.htm>.

CANDIAGO, S., et al. **Evaluating multispectral images and vegetation indices for precision farming applications from UAV images**. Remote sensing, 7(4), 4026-4047, 2015.

CABRAL, D. de C. **Na presença da floresta: Mata Atlântica e história colonial**. Rio de Janeiro: Garamond: Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro - Faperj, 535 p, 2014.

CARVALHO, S. A. D. de; FURTADO, A. T. **O melhoramento genético de cana-de-açúcar no Brasil e o desafio das mudanças climáticas globais**. Revista Gestão & Conexões, Vitória: Universidade Federal do Espírito Santo - UFES, Programa de Pós-Graduação em Administração, v. 2, n. 1, p. 22-46, 2013.

CASTILLO, R. **Dinâmicas recentes do setor sucroenergético no Brasil: competitividade regional e expansão para o bioma cerrado**. GEOgraphia, Niterói: Universidade Federal Fluminense - UFF, Programa de Pós-Graduação em Geografia, v. 17, n. 35, p. 95-119, 2015.

CÂMARA, G., Davis, C., MONTEIRO, A. M. V. **Introdução à ciência da geoinformação**. 2001.

CAMPS, A. **Nanosatellites and applications to commercial and scientific missions**. 2020.

CARREIRA-PERPINÁN, M. A. **A review of mean-shift algorithms for clustering**. University of California, 2015.

CHARTZOULAKIS, K.; Bertaki, M. **Sustainable water management in agriculture under climate change**. Agric. Sci. Procedia 2015, 4, 88–98.

CNES, Centre national d'études spatiales. **Orfeo Tool Box – OTB**, v.7.5, www.orfeo-toolbox.org/, 2020.

CHERUBIN, Maurício Roberto, et al. **Amostragem de solo na agricultura de precisão**. Agricultura de precisão no Rio Grande do Sul. CESPOL, p. 79-98, 2016.

CIRANI, Claudia; MORAES, Márcia. **Inovação na indústria sucroalcooleira paulista: os determinantes da adoção das tecnologias de agricultura de precisão**. Revista de Economia e Sociologia Rural, v. 48, p. 543-565, 2010.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: Principles and practices**. (2nd Edition). Boca Raton, FL, USA: CRC Press, 2009.

COELHO, José Pimentel Castro et al. **Agricultura de precisão**. Associação dos Jovens Agricultores de Portugal, 2009.

CSILLIK, O. et al. **Object-based time-constrained dynamic time warping classification of crops using Sentinel-2**. Remote Sensing, 11, 1257, 2019.

CUADRA, S. V., et al. **Modelagem agroambiental e a transformação digital da agricultura**. Embrapa Informática Agropecuária-Capítulo em livro científico (ALICE), 2020.

DO SUL, M. G. **Evolução da produção de soja e pecuária bovina e pecuária bovinda do estado de Mato Grosso do Sul**, 2016.

DA SILVA, H., et al. **Aspectos técnicos e econômicos da produção de etanol de milho no Brasil**. Revista de Política Agrícola, 29, dez. 2020. Disponível em: <<https://seer.sede.embrapa.br/index.php/RPA/article/view/1567>>. Acesso em: 23 Dez.2021.

DA SILVA, A. O. **A fertirrigação e o processo de salinização de solos em ambiente protegido**. Nativa, 2(3), 180-186, 2014.

DA SILVA, Aletéia PM; et al. **Aplicação de vinhaça na cultura da cana-de-açúcar: Efeito no solo e na produtividade de colmos**. Revista Brasileira de Engenharia Agrícola e Ambiental, v. 18, p. 38-43, 2014.

DA SILVA, S. P. **A impotência da biomassa na matriz energética brasileira**. Pensar Acadêmico, 19(2), 557-583, 2021.

DA SILVA, Wanderson de Vasconcelos Rodrigues; SILVA-MANN, Renata. **Agricultura de Precisão no Brasil: conjuntura atual, desafios e perspectivas**. Research, Society and Development, v. 9, n. 11, p. e1979119603-e1979119603, 2020.

DAUGHTRY, C.S.T. et al. **Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance**. Remote Sensing of Environment, 74, 229–239, 2000.

DE OLIVEIRA, A. J., et al. **Potencialidades da utilização de drones na agricultura de precisão**. Brazilian Journal of Development, 6(9), 64140-64149, 2020.

DIAS, F. M. F. **Alguns elementos sobre a cadeia produtiva da cana-de-açúcar no Brasil**. Geosul, 36(79), 116-142, 2021.

DEFINIENS. **Definiens Professional 5 Reference Book**. Definiens AG, München, Germany, 2006.

DE CASTRO, A.I. et al. **An Automatic Random Forest-OBIA Algorithm for Early Weed Mapping between and within Crop Rows Using UAV Imagery**. Remote Sensing of environment, 10, 285, 2018.

DE CASTRO, Selma Simões et al. **A expansão da cana-de-açúcar no Cerrado e no Estado de Goiás: elementos para uma análise espacial do processo**. Boletim Goiano de Geografia, v. 30, n. 1, p. 171-191, 2010.

DE CASTRO, A. et al. **3-D characterization of vineyards using a novel UAV imagery-based OBIA procedure for precision viticulture applications**. Remote Sensing of environment. 10, 584, 2018.

DE LUCA, G., et al. **Object-based land cover classification of cork oak woodlands using UAV imagery and Orfeo ToolBox**. *Remote Sensing of environment*, 11(10), 1238, 2019.

DE MEY, S. **The Future of Satellite Applications: The End-User Perspective**. In *Yearbook on Space Policy 2015* (pp. 175-191). Springer, Vienna, 2017.

DE MIRANDA, Ana Clara Cavalcanti; et al. **Agricultura de precisão: um mapeamento da base da Scielo**. *GESTÃO. Org*, v. 15, n. 6, p. 129-137, 2017.

DE OLIVEIRA, M. H. R., et al. **Produtividade da cana-de-açúcar sob irrigação localizada: uma revisão sistemática**. *Research, Society and Development*, 9(7), e104973966-e104973966, 2020.

DE SOUZA, Jânio Kleiber Camelo et al. **Fertirrigação com vinhaça na produção de cana-de-açúcar**. *Agropecuária Científica no Semiárido*, v. 11, n. 2, p. 7-12, 2015.

DE SOUZA, C. H. W., et al. **Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images**. *Computers and Electronics in Agriculture*, 143, 49-56, 2017.

DIONYS, Forster. **Mapping diversified peri-urban agriculture – potential of object-based versus per-field land cover/land use classification**, *Geocarto International*, 25:3, 171-186, 2010.

DOS SANTOS FERREIRA, A. et al. **Weed detection in soybean crops using ConvNets**. *Comput. Electron. Agric.*, 143, 314–324, 2017.

DOS SANTOS Luciano, A. C., et al. **A generalized space-time OBIA classification scheme to map sugarcane areas at regional scale, using Landsat images time-series and the random forest algorithm**. *International Journal of Applied Earth Observation and Geoinformation*, 80, 127-136, 2019.

DUBEY, S.K., GAVLI, A.S., YADAV, S.K. et al. **Remote Sensing-Based Yield Forecasting for Sugarcane (*Saccharum officinarum* L.) Crop in India**. *J Indian Soc Remote Sens* 46, 1823–1833, 2018.

ESTEVEZ, L. M. **Meio ambiente & botânica** (Vol. 12). Senac, 2017.

ESETLILI, M. T., et al. **Comparison of object and pixel-based classifications for mapping crops using Rapideye imagery: a case study of Menemen Plain, turkey**. *International Journal of Environment and Geoinformatics*, 5(2), 231-243, 2018.

FU W., Ma J., Chen P., Chen F. **Remote Sensing Satellites for Digital Earth**. In: Guo H., Goodchild M.F., Annoni A. (eds) *Manual of Digital Earth*. Springer, Singapore. https://doi.org/10.1007/978-981-32-9915-3_3, 2020.

FREYRE, G. **Nordeste: aspectos da influência da cana sobre a vida e a paisagem do nordeste do Brasil**. 7. ed. rev. São Paulo: Global, 255 p., 2004.

FRAVET, P. R. F. de et al. **Efeito de doses de torta de filtro e modo de aplicação sobre**

a produtividade e qualidade tecnológica da soqueira de cana-de-açúcar, Ciência e Agrotecnologia, Lavras: Ed. UFLA, v. 34, n. 3, p. 618-624, maio/jun. 2010.

FORMAGGIO, A. R., Sanches, I. D. A. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017.

FRESCO, L. O., POPPE, K. J. **Towards a common agricultural and food policy**. Wageningen University & Research, 2016.

FILIP, M., Zoubek, T. et al. **Advanced Computational Methods for Agriculture Machinery Movement Optimization with Applications in Sugarcane Production**. Agriculture, 10(10), 434, 2020.

FORTES, C. and DEMATTE, J.A.M. **Discrimination of sugarcane varieties using Landsat 7 ETM+ spectral data**. International Journal of Remote Sensing, 27, pp. 395–1412, 2006.

FORSTER, D., et al. **Mapping Diversified peri-urban agriculture—potential of object-based versus per-field land cover/land use classification**. Geocarto International, 25(3), 171-186, 2015.

GEWIN, V. **Mapping opportunities**. Nature, 427(6972), 376-377, 2004.

GAVA, G. J de C. et al. **Produtividade de três cultivares de cana-de-açúcar sob manejos de sequeiro e irrigado por gotejamento**. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande: Universidade Federal de Campina Grande - UFCG, Unidade Acadêmica de Engenharia Agrícola - UAEEA, v. 15, n. 3, p. 250-255, mar. 2011. Disponível em: <http://www.agriambi.com.br/index.php?option=com_content&view=article&id=21&Itemid=11>. Acesso em: janeiro 2022.

GALVÃO, L. S., FORMAGGIO, A. R., and TISOT, D. A. **Discrimination of Sugarcane Varieties in Southeastern Brazil with EO-1 Hyperion Data**. Remote Sensing of Environment, 94: 523 – 534, 2005.

GARRE, P.; Harish, A. **Autonomous Agricultural Pesticide Spraying UAV**. In IOP Conference Series: Materials Science and Engineering; IOP Publishing: Bristol, UK, 2018; Volume 455, p. 012030. 89, 2018.

Xue, X.; et al. **Develop an unmanned aerial vehicle based automatic aerial spraying system**. Comput. Electron. Agric. 128, 58–66, 2016.

GRIZONNET, M., et al. **Orfeo ToolBox: open source processing of remote sensing images**. Open Geospatial Data, Software and Standards, 2(1), 1-8, 2017.

GOMARASCA, M. A., et al. **Sentinel for applications in agriculture**. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 2019.

GASCON, F., et al. **Status of Current and Expansion Missions of the Copernicus Optical Imaging Family**. In EGU General Assembly Conference Abstracts, p. 21491, 2020.

GOEL, N.S. and STREBEL, D.E. **Simple beta distribution representation of leaf orientation in vegetation canopies**. *Agronomy Journal*, 76, pp. 800–803, 1984.

GERS, C.J. **Applications of remote sensing in sugarcane agriculture at Umflozi, South Africa**. MSc thesis, School of Environmental Sciences, University of KwaZulu-Natal, Pietermaritzburg, South Africa, 2004.

GERS, C.J. **Remotely sensed sugarcane phenological characteristics at Umflozi South Africa**. In Proceedings of the 2003 IEEE International Geoscience and Remote Sensing Symposium, July 2003, Toulouse, France, Vol. II (IEEE Operations Centre, Hoes Lane: Institute of Electrical and Electronic Engineers, Inc.), pp. 1010–1012, 2003.

GALVÃO, L.S., FORMAGGIO, A.R. and TISOT, D.A. **The influence of spectral Resolution on discriminating Brazilian sugarcane varieties**. *International Journal of Remote Sensing*, 24, pp. 769–777, 2018.

GITELSON, A.A.; et al. **Relationship between gross primary production and chlorophyll content in crops: Implications for the synoptic monitoring of vegetation productivity**. *J. Geophys. Res.* 111, D08S11, 2006.

GROF, C. P. and CAMPBELL, J. A. **Sugarcane sucrose metabolism: scope for molecular manipulation**. *Functional Plant Biology* 28(1), 1–12, 2001.

GALEANO, E. **Previsão de produção da agricultura para o ano de 2021**. Boletim da Conjuntura Agropecuária Capixaba. 2021. Disponível em: <http://biblioteca.incaper.es.gov.br/digital/handle/123456789/4237>

GITELSON, A.A.; MERZYAK, M.N. **Remote estimation of Chlorophyll Content in Higher Plant Leaves**. *Int. J. Remote Sens.* 18, 2691–2697, 1997.

GUAN, K.; et al. **The shared and unique values of optical, fluorescence, thermal and microwave satellite data for estimating large-scale crop yields**. *Remote Sens. Environ.* 199, 333–349, 2017.

HUANXUE ZHANG, et al. **Automated delineation of agricultural field boundaries from Sentinel-2 images using recurrent residual U-Net**. *International Journal of Applied Earth Observation and Geoinformation*, Volume 105, 2021.

HAMAR, D., FERENCZ, C., LICHTENBERGER, J., TARCSAI, G., & FERENCZ-ARKOS, I. **Yield estimation for corn and wheat in the Hungarian Great Plain using Landsat MSS data**. *International Journal of Remote Sensing*, 17(9), 1689–1699, 1996.

HAN, L.; et al. **Clustering field-based maize phenotyping of plant-height growth and canopy spectral dynamics using a UAV remote-sensing approach**. *Front. Plant Sci.* 9, 1638, 2018.

HOSSAIN, M.D.; CHEN, D. **Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective**. *ISPRS J. Photogramm. Remote Sens.* 150, 115–134, 2019.

HAMADA, E. **Água, agricultura e meio ambiente no Estado de São Paulo: avanços e desafios**. Embrapa Meio Ambiente-Livro científico (ALICE), 2003.

HUETE, A.R. **Soil influences in remotely sensed vegetation-canopy spectra**. In **Theory and Applications of Optical Remote Sensing**. G. Asrar (Ed.), pp. 107–141 (New York: Wiley Interscience). 2005.

HUANG, Y.; et al. **Agricultural remote sensing big data: Management and applications**. *J. Integr. Agric.* 17, 1915–1931, 2018.

IBGE. **A Geografia da cana-de-açúcar**. IBGE, Coordenação de Geografia. - Rio de Janeiro : IBGE, 2017.

IBGE, 2019. **Cartograma - Cana-de-açúcar do Brasil por Quantidade produzida em toneladas**. Disponível em: https://censos.ibge.gov.br/agro/2017/templates/censo_agro/resultadosagro/agricultura.htm. Acessado em: 20 novembro 2021.

ISA, D.W., HOFMAN, G. and VAN CLEEMPUT, O. **Uptake and balance of Fertilizer nitrogen applied to sugarcane**. *Field Crops Research*, 95, pp. 348–354, 2021.

INGLADA, J., & CHRISTOPHE, E. **The Orfeo Toolbox remote sensing image processing software**. In 2009 IEEE International Geoscience and Remote Sensing Symposium (Vol. 4, pp. IV-733). IEEE, 2009.

IMMITZER, M., Vuolo, F., & Atzberger, C. **First experience with Sentinel-2 data for crop and tree species classifications in central Europe**. *Remote sensing*, 8(3), 166, 2016.

JOHNSON, A. K. L., & KINSEY-HENDERSON, A. E. **Satellite-based remote sensing for monitoring land use in the sugar industry**, 1997.

JOHNSON, R.M., VIATOR, R.P., VEREMIS, C.J., RICHARD, E.P. and ZIMBA, P. **Discrimination of sugarcane varieties with hyperspectral reflectance measurements and plant pigment analysis**. *Journal of the American Society of Sugar Cane Technologists*, 25, pp. 111–112, 2005.

JOHANSEN, K., et al. **Center pivot field delineation and mapping: A satellite-driven object-based image analysis approach for national scale accounting**. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175, 1-19, 2021.

JUNG, J.; et al. **Unmanned aerial system assisted framework for the selection of high yielding cotton genotypes**. *Comput. Electron. Agric.* 152, 74–81, 2018.

JAWAK, S. D., DEVLİYAL, P., & LUIS, A. J. **A comprehensive review on pixel oriented and object oriented methods for information extraction from remotely sensed satellite images with a special emphasis on cryospheric applications**. *Advances in Remote Sensing*, 4(03), 177, 2015.

KAVATS, Olena et al. **Monitoring of sugarcane harvest in Brazil based on Optical and SAR data**. *Remote Sensing*, v. 12, n. 24, p. 4080, 2020.

LAIME, Eduardo Maciel et al. **Possibilidades tecnológicas para a destinação da vinhaça**. Revista Trópica: Ciências Agrárias e Biológicas, v. 5, n. 3, 2011.

LANDELL, M. G. de A. et al. **Sistema de multiplicação de cana-de-açúcar com uso de mudas pré-brotadas (MPB), oriundas de gemas individualizadas**. Campinas: Instituto Agrônômico - IAC, 16 p. (Documentos IAC, n. 109), 2012.

LEONARDO F. Maldaner, et al. **Identification and measurement of gaps within sugarcane rows for site-specific management: Comparing different sensor-based approaches**. Biosystems Engineering, Volume 209, Pages 64-73, 2021.

LEI MA, et al. **A review of supervised object-based land-cover image classification**. ISPRS Journal of Photogrammetry and Remote Sensing, Volume 130, Pages 277-293. 2017.

LEAL, M. R. L., et al. **Sugarcane straw availability, quality, recovery and energy use: a literature review**. Biomass and Bioenergy, 53, 11-19. 2013.

LI, M., et al. **A review of remote sensing image classification techniques: The role of spatio-contextual information**. European Journal of Remote Sensing, 47(1), 389-411. 2014.

LINSLEY, C. M., & BAUER, F. C. **Test your soil for acidity**. Circular, University of Illinois, Agricultural Experiment Station; no. 346. 1929.

LONG, J. A., et al. **Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest**. GIScience & Remote Sensing, 50(4), 418-436. 2013.

LOPES, Maurício Antônio; CONTINI, Elisio. **Agricultura, sustentabilidade e tecnologia**. Agroanalysis, v. 32, n. 02, p. 27-34, 2012.

LUTHER, J.E. and CARROLL, A.L. **Development of an index of balsam fir vigour By foliar spectral reflectance**. Remote Sensing of Environment, 69, pp. 241–252. 2004.

LU, D., & WENG, Q. **A survey of image classification methods and techniques for improving classification performance**. International journal of Remote sensing, 28(5), 823-870. 2007.

MASONI, A., ERCOLI, L., MARIOTTI, M. and BARBIERI, P. **Changes in Spectral properties of ageing and senescing maize and sunflower leaves**. Physiologia Plantarum, 91, pp. 334–338. 1994.

MACDONALD, R. B., & Hall, F. G. **The large area crop inventory experiment: A major demonstration of space remote sensing**. In W. Nordberg Mem. Symp. on Contrib. of Space Observ. to Global Food Inform. Systems (No. COSPAR-D. 2.3). 1977.

MAESTRINI, Bernardo; BASSO, Bruno. **Drivers of within-field spatial and temporal variability of crop yield across the US Midwest**. Scientific reports, v. 8, n. 1, p. 1-9, 2018.
MA, L., et al. **A review of supervised object-based land-cover image classification**. ISPRS Journal of Photogrammetry and Remote Sensing, 130, 277-293. 2017.

MENDES, R. da S. **Paisagens culturais da Baixada Fluminense**. São Paulo: Universidade de São Paulo - USP, Faculdade de Filosofia, Ciências e Letras, 171 p. (Boletim, n. 110. Geografia, n. 4). 1950.

MESQUITA, F. C. **Conhecimento localizado no agronegócio: evidências da agroindústria canieira em Goiás**. In: ENCONTRO DA ASSOCIAÇÃO NACIONAL DE PÓS-GRADUAÇÃO E PESQUISA EM GEOGRAFIA, 11., Presidente Prudente. Anais... Dourados: Anpege, 2015a. p. 9574-9583. 2015.

McBratney, A., et al. **Future directions of precision agriculture**. Precision agriculture, 6(1), 7-23. 2015.

VOGELS, M.F.A., et al. **Mapping irrigated agriculture in complex landscapes using SPOT6 imagery and object-based image analysis – A case study in the Central Rift Valley, Ethiopia**. International Journal of Applied Earth Observation and Geoinformation, Volume 75, Pages 118-129, 2019.

MILANEZ, Artur Yabe; NYKO, Diego. **O futuro do setor sucroenergético e o papel do BNDES**. 2012.

MILANEZ, A. Y., et al. **A produção de etanol pela integração do milho-safrinha às usinas de cana-de-açúcar: avaliação ambiental, econômica e sugestões de política**. 2014.

MOGILI, U.R.; DEEPAK, B. **Review on application of drone systems in precision agriculture**. Procedia Comput. Sci. 133, 502–509. 2018.

MOLIJN, Ramses A., et al. **Sugarcane Productivity Mapping through C-Band and L-Band SAR and Optical Satellite Imagery**. Remote Sensing 11, no. 9: 1109. 2019.

MOLIN, Jose Paulo; ANSELMINI, Adriano Adalcino. **Agricultura de precisão considera variabilidade das áreas de cultivo**. Visão Agrícola, v. 13. 2016.

MORA, A.; et al. **Land cover classification from multispectral data using computational intelligence tools: A comparative study**. Information, 8, 147. 2017.

MORAN, M. S., et al. **Opportunities and limitations for image-based remote sensing in precision crop management**. Remote sensing of Environment 61(3), 319-346 (1997).

MOORE, P. H.; PATERSON, A. H.; TEW, T. **Sugarcane: the crop, the plant, and domestication**. In: MOORE, P. H.; BOTHA, F. C. (Ed.). Sugarcane: physiology, biochemistry and functional biology. Ames: Wiley-Blackwell, p. 1-17. 2014.

MUCHOW, R.C., SPILLMAN, M.F., WOOD, A.W. and THOMAS, M.R. **Radiation interception and biomass accumulation in a sugarcane crop grown under irrigated tropical conditions**. Australian Journal of Agricultural Research, 45, pp. 37–49. 1994.

MUCHOW, R.C., ROBERTSON, M.J., WOOD, A.W. and KEATING, B.A. **Effect of nitrogen on the time-course of sucrose accumulation in sugarcane**. Field Crops Research, 47, pp. 143–153. 1996.

MUTANGA, O., et al. **Predicting In Situ Pasture Quality in The Krugar National Park, South Africa, Using Continuum-removed Absorption Features.** Remote Sensing of Environment, 89: 393 – 408. 2011.

MONTERO, D.; RUEDA, C. **Detection of palm oil bud rot employing artificial vision.** In IOP Conference Series Materials Science and Engineering; IOP Publishing: Bristol, UK, 2018; Volume 437, p. 012004.

MOGILI, U. R., & DEEPAK, B. B. V. L. **An intelligent drone for agriculture applications with the aid of the mavlink protocol.** In Innovative Product Design and Intelligent Manufacturing Systems (pp. 195-205). Springer. 2020.

MARTINS, A. P., & ROSA, R. **Procedimentos metodológicos para estimativa de variáveis relacionadas ao balanço de energia no sistema terra-atmosfera-uma revisão da literatura.** Caderno Prudentino de Geografia, 1(41), 100-119. 2019.

Matheus, A. V., et al. **Object Based Image Analysis and Data Mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas.** Remote Sensing of Environment, Volume 123, Pages 553-562, 2012.

MARKLEY, J., Raines, A., & CROSSLEY, R. (2003). **The development and integration of remote sensing, GIS and data processing tools for effective harvest management.** In 2003 Conference of the Australian Society of Sugar Cane Technologists held at Townsville, Queensland, Australia, 6-9 May 2003.

NIMER, E. **Climatologia do Brasil.** Rio de Janeiro: IBGE, 421 p. 1979.

NARCISO, G., e SCHMIDT, E. **Identification and classification of sugarcane based on satellite remote sensing.** In Proceedings of the South African Sugar Technologists' Association (Vol. 73, pp. 189-194). 1999.

NAKALEMBE, C., et al. **Sowing seeds of food security in africa.** Eos (Washington. DC), 102. 2021.

OLIVEIRA FILHO, Francisco X. de et al. **Zona de manejo para preparo do solo na cultura da cana-de-açúcar.** Revista Brasileira de Engenharia Agrícola e Ambiental, v. 19, p. 186-193, 2015.

OLIVEIRA, O. H. D., et al. **Produção de biomassa de cana-de-açúcar em fase de estabelecimento.** Revista Brasileira de Gestão Ambiental e Sustentabilidade, 7(17), 1379-1389. 2020.

OLIVEIRA, T. B. A., et al. **Tecnologia e custos de produção de cana-de-açúcar: um estudo de caso em uma propriedade agrícola.** Latin American Journal of Business Management, 3(1). 2012.

PYTHON SOFTWARE FOUNDATION. **Python Language Reference**, version 3.4. 2014. Available at <http://www.python.org>.

QUEBRAJO, L.; et al. **Thermal imaging and soil remote sensing to enhance irrigation management of sugar beet**. *Biosyst. Eng.* 2018, 165, 77–87.

QGIS DEVELOPMENT Team. 2019. **Qgis Geographic Information System**. Open Souce Geospatial Foundation Project. <http://qgis.osgeo.org>

KASPER JOHANSEN, et al. **Using GeoEye-1 Imagery for Multi-Temporal Object-Based Detection of Canegrub Damage in Sugarcane Fields in Queensland**. Australia, *GIScience & Remote Sensing*, 55:2, 285-305, 2018.

KAMILARIS, A., PRENAFETA-BOLDÚ, F. X. **Deep learning in agriculture: A survey**. *Computers and electronics in agriculture*, 147, 70-90. 2018.

KUMAR, L., et al. **Imaging Spectrometry and Vegetation Science**. In F. D. van de Meer and S. M. de Jong (Eds.), *Imaging Spectrometry: Basic Principles and Prospective Applications*. (pp 111- 155), Dordrecht: Kluwer Academic Press, The Netherlands. 2003.

KIRCHNER, L., LEE LOVICK, G. **The use of Landsat TM data for the assessment and monitoring of sugarcane**. *Remote Sensing*, 1087—1095. 1991.

KIM, M., et al. **Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects**. *International Journal of Remote Sensing*, 32(10), 2825-2850. 2015.

KOEHLER, H. S., et al. **O sistema radicular da variedade RB855536 de cana-de-açúcar no plantio em minitotele e tolete**. *Scientia Agraria*, 10(5), 343-349. 2009.

PACHECO, J. M., & Hoff, D. N. **Fechamento de Ciclo de Matéria e Energia no Setor Sucroalcooleiro**. *Sustainability in Debate/Sustentabilidade em Debate*, 4(2). 2013.

PETRONE, M. T. S. **A lavoura canvieira em São Paulo: expansão e declínio (1765-1851)**. São Paulo: Difusão Européia do Livro, 241 p. 1968.

PONZONI, F. J., Shimabukuro, Y. E., & Kuplich, T. M. **Sensoriamento remoto da vegetação**. *Oficina de Textos*. 2015.

PEÑA, J. M., et al. **Object-based image classification of summer crops with machine learning methods**. *Remote Sensing*, 6(6), 5019-5041., 2014.

PURI, V., A. NAYAR, and L. Raja. **Agriculture drones: A modern breakthrough in precision agriculture**. *Journal of Statistics and Management Systems*, vol. 20, no. 4, pp. 507–518, 2017.

RAJESH, D. **Application of spatial data mining for agriculture**. *International Journal of Computer Applications*, 15(2), 7-9., 2011.

RUDORFF, B. F. T., & Batista, G. T. **Yield estimation of sugarcane based on agrometeorological-spectral models**. *Remote sensing of Environment*, 33(3), 183-192., 1990.

RODRIGUES, Délcio; ORTIZ, Lúcia. **Em direção à sustentabilidade da produção de etanol de cana-de-açúcar no Brasil**. Porto Alegre, Brazil: Amigos da Terra Brasil, 2006.

ROCHA, F. J., 2012. **Desenvolvimento e produtividade da cana-de-açúcar submetida a diferentes doses de vinhaça**. Tese de doutorado, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba. Doi: 11606/T.11.2012.tde-18012013-161316. Retrieved 2021-12-28.

ROSSETTO, R.; SANTIAGO, A. D. **Plantio da cana-de-açúcar**. Brasília, DF: Agência Embrapa de Informação Tecnológica - Ageitec, 2015. Disponível em <http://www.agencia.cnptia.embrapa.br/gestor/cana/eacucar/rvore/CONTAG01_33_711200516717.html>. Acesso em: abr. 2022.

SACCON, P. **Water for agriculture, irrigation management**. Appl. Soil Ecol. 2018, 123, 793–796.

SÃO PAULO: **Associação Nacional de Pós-Graduação e Pesquisa em Ambiente e Sociedade - ANPPAS**, v. 6, n. 1, p. 23-44, jan./jun. 2003. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1414-753X2003000200003&lng=en&nrm=iso&tlng=pt>. Acesso em: out. 2021.

SOBRINHO, O. P. L., et al. **A cultura da cana-de-açúcar (*Saccharum officinarum*) e o manejo da irrigação**. Revista em Agronegócio e Meio Ambiente, 12(4), 1605-1625, 2019.

SILVA, P. M. S. da et al. **Um estudo de caso da produção agrícola familiar de derivados de cana-de-açúcar em Assis Chateaubriand-PR**. In: ENCONTRO DE ECONOMIA PARANAENSE, 11., 2014, Apucarana. Anais... Apucarana: Universidade Estadual do Paraná - Unespar, 18 p., 2014.

SÃO PAULO (Estado). Lei nº 11.241, de 19 de setembro de 2022. **Dispõe sobre a eliminação gradativa da queima da palha da cana-de-açúcar e dá providências correlatas**. Diário Oficial do Estado de São Paulo; Poder Executivo: São Paulo, Seção I, 112 (180), 2022.

SCARLETT, Andrew J. **Integrated control of agricultural tractors and implements: a review of potential opportunities relating to cultivation and crop establishment machinery**. Computers and electronics in agriculture, v. 30, n. 1-3, p. 167-191, 2001.

SCHMIDT, E.J., NARCISO, G., FROST, P. and GERS, C.J., 2000. **Application of remote sensing technology in the South African sugar industry: a review of recent research findings**. Proceedings of the South African Sugar Technologists' Association, 74, pp. 192–201, 2000.

SENTINEL APPLICATION PLATFORM – SNAP. **European Space Agency – ESA**. Version 8.0. 2021.

SILVEIRA, José Maria Ferreira Jardim da; BORGES, Izaias de Carvalho; BUAINAIN, Antonio Márcio. **Biotechnologia e agricultura: da ciência e tecnologia aos impactos da inovação**. São Paulo em Perspectiva, v. 19, p. 101-114, 2005.

SIMÕES, M.D.S., ROCHA, J.V. and LAMPARELLI, R.A.C., 2005, **Spectral variables, growth analysis and yield of sugarcane**. *Scientia Agricola* (Piracicaba, Brazil), 62, pp. 199–207, 2005.

SINGELS, A., et al. **The effect of crop start date, crop class and cultivar on sugarcane canopy development and radiation interception**. *Field Crops Research*, 92, pp. 249–260, 2005.

SHEFFIELD, J. et al. **Satellite remote sensing for water resources management: Potential for supporting sustainable development in data-poor regions**. *Water Resources Research*, 54(12), 9724-9758, 2018.

SOM-ARD, Jaturong, et al. **Remote Sensing Applications in Sugarcane Cultivation: A Review**. *Remote Sensing* 13, no. 20: 4040, 2021.

SOTHE, C. et al. **Abordagens para classificação do estágio sucessional da vegetação do parque nacional de são Joaquim empregando imagens landsat-8 e rapideye**. *Boletim de Ciências Geodésicas*, 23, 389-404, 2017.

ŠIMEK, P., RAJTR, J., VASILENKO, A., & VOKOUN, T. **Analysis of earth remote sensing data sets and their usability in the agricultural sector**. *Agrarian Perspectives XXVII.*, 395, 2018.

SEGARRA, J. et al. **Remote sensing for precision agriculture: Sentinel-2 improved features and applications**. *Agronomy*, 10(5), 641, 2020.

SHUKLA, G., Garg, et al. **Implementation of random forest algorithm for crop mapping across an aridic to ustic area of Indian states**. *Journal of Applied Remote Sensing*, 11(2), 026005, 2017.

SOBRINHO, O. P. L. **A cultura da cana-de-açúcar (*Saccharum officinarum*) e o manejo da irrigação**. *Revista em Agronegócio e Meio Ambiente*, 12(4), 1605-1625, 2019.

T. BLASCHKE., **Object based image analysis for remote sensing**. *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 65, Issue 1, Pages 2-16, ISSN 0924-2716, 2010.

TEJERA, N.A., RODE´ S, R., ORTEGA, E. **Comparative analysis of Physiological characteristics and yield components in sugarcane cultivars**. *Field Crops Research*, 102, pp. 67–72, 2007.

TEIXEIRA, J. C., HESPANHOL, A. N. **A expansão canavieira no contexto da produção agropecuária da bacia hidrográfica do rio Ivinhema no Estado de Mato Grosso do Sul**. *Revista Campo-Território*, 11(24 Ago.), 2019.

TULIP, J.R. and WILKINS, K. **Application of spectral unmixing to trash level Estimation in billet cane**. *Proceedings of the Australian Society of Sugar Cane Technology*, 27, pp.387–399, 2005.

TZOTSOS, A., ARGIALAS, D. **Support vector machine classification for object-**

based image analysis. In *Object-Based Image Analysis* (pp. 663-677). Springer, Berlin, Heidelberg, 2008.

UENO, M., KAWAMITSU, Y., SUN, L., TAIRA, E. and MAEDA, K., 2005, **Combined applications of NIR, RS and GIS for sustainable sugarcane production.** *Sugarcane International*, 23, pp. 8–11, 2005.

VEDANA, R., et al. **Distribuição espacial da produtividade de cana-de-açúcar no Brasil.** *Revista de Política Agrícola*, 28(4), 121, 2020.

VITTI, G. C.; MAZZA, J. A. **Planejamento, estratégias de manejo e nutrição da cultura de cana-de-açúcar.** Piracicaba: Potafos, 2002. 16 p. (Encarte técnico. Informações agronômicas, n. 97), 2002. Disponível em: <[http://www.ipni.net/PUBLICATION/IA-BRASIL.NSF/0/504B40E488537AE083257AA2005EA7F6/\\$FILE/Encarte%2097.pdf](http://www.ipni.net/PUBLICATION/IA-BRASIL.NSF/0/504B40E488537AE083257AA2005EA7F6/$FILE/Encarte%2097.pdf)>. Acesso em: jun 2022. 2017.

VICTORIA FILHO, R.; CHRISTOFFOLETI, P. J. **Manejo de plantas daninhas e produtividade da cana.** *Visão Agrícola*, Piracicaba: Escola Superior de Agricultura “Luiz de Queiroz” - Esalq, n. 1, p. 32-37, jan./jun. 2004. Disponível em: <<http://www.esalq.usp.br/visaoagricola/edicoes/cana-de-acucar>>. Acesso em: jul. 2022.

VAN DER MEER, F. D., de JONG, S. M., and BAKKER, W., 2003: **Imaging Spectrometry; Basic Analytical Techniques.** In F. D. van de Meer and S. M. de Jong (Eds.), *Imaging Spectrometry: Basic Principles and Prospective Applications.* (pp 17- 61), Dordrecht: Kluwer Academic Press, The Netherland, 2003.

VOGELS, M. F. et al.. **Spatio-temporal patterns of smallholder irrigated agriculture in the horn of Africa using GEOBIA and Sentinel-2 imagery.** *Remote Sensing*, 11(2), 143, 2019.

VIEIRA, M. A. et al. **Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas.** *Remote Sensing of Environment*, 123, 553-562, 2012.

VATSAVAI, R. R. **Object based image classification: state of the art and computational challenges.** In *Proceedings of the 2nd ACM SIGSPATIAL International Workshop on Analytics for Big Geospatial Data* (pp. 73-80), 2013.

XAVIER, A.C., RUDORFF, B.F.T., SHIMABUKURO, Y.E., BERKA, L.M.S. and MOREIRA, M.A. **Multi-temporal analysis of MODIS data to classify sugarcane crop.** *International Journal of Remote Sensing*, 27, pp. 755–768, 2006.

HANG, H. **Automated delineation of agricultural field boundaries from Sentinel-2 images using recurrent residual U-Net.** *International Journal of Applied Earth Observation and Geoinformation*, 105, 102557, 2021.

ZARCO-TEJADA, P.J.; GONZÁLEZ-DUGO, M.V.; FERERES, E. **Seasonal stability of chlorophyll fluorescence quantified from airborne hyperspectral imagery as an indicator of net photosynthesis in the context of precision agriculture.** *Remote Sens. Environ.*, 179, 89–103, 2016.

ZHAO, D. H., LI, J. L., QI, J. G. **Identification of Red and Near Infra-Red Spectral Regions and Vegetative Indices for Discrimination of Cotton Nitrogen Stress and Growth Stage.** *Computers and Electronics in Agriculture*, 48: 155 – 169, 2005.

ZHANG, Q. et al. **Integrating chlorophyll fAPAR and nadir photochemical reflectance index from EO-1/Hyperion to predict cornfield daily gross primary production.** *Remote Sens. Environ.*, 186, 311–321. 2016.

WAHAB, I.; Hall, O.; JIRSTRÖM, M. **Remote Sensing of Yields: Application of UAV Imagery-Derived NDVI for Estimating Maize Vigor and Yields in Complex Farming Systems in Sub-Saharan Africa.** *Drones*, 2, 28, 2018.

WACHHOLZ, de Souza. **Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images,** *Computers and Electronics in Agriculture*, Volume 143, 2017, Pages 49-56, ISSN 0168-1699, 2017.

WHELAN, Brett; TAYLOR, James. **Precision agriculture for grain production systems.** Csiro publishing, 2013.

WISE, Timothy A. **Can we feed the world in 2050. A scoping paper to assess the evidence.** Global Development and Environment Institute Working Paper, n. 13-04, 2013.

WHITCRAFT, A. K., BECKER-RESHEF, I., JUSTICE, C. O. **NASA Harvest (ing) Earth Observations for Informed Agricultural Decisions.** In *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium* (pp. 3706-3708). IEEE, 2020.

WORSTER, D. **Transformações da terra: para uma perspectiva agroecológica na história.** *Ambiente & sociedade*, 5, 23-44, 2003.

YENGOH, G. T., et al. **Use of the Normalized Difference Vegetation Index (NDVI) to assess Land degradation at multiple scales: status, future trends, and practical considerations.** Springer, 2015.