

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ  
CAMPUS CASCAVEL  
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

**APLICAÇÃO COMPUTACIONAL AGDATABOX-RS: GERENCIAMENTO DE DADOS DE  
SENSORIAMENTO REMOTO**

**GIUVANE CONTI**

**CASCAVEL – PR**

**2021**

**GIUVANE CONTI**

**APLICAÇÃO COMPUTACIONAL AGDATABOX-RS: GERENCIAMENTO DE DADOS DE  
SENSORIAMENTO REMOTO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Erivelto Mercante  
Coorientador: Prof. Dr. Eduardo Godoy de Souza

**CASCADEL – PR**

**2021**

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Conti, Giuvane

APLICAÇÃO COMPUTACIONAL AGDATABOX-RS : GERENCIAMENTO DE DADOS DE SENSORIAMENTO REMOTO / Giuvane Conti; orientador(a), Erivelto Mercante; coorientador(a), Eduardo Godoy de Souza, 2021.

70 f.


Tese (doutorado), Universidade Estadual do Oeste do Paraná, Campus de Cascavel, Centro de Ciências Exatas e Tecnológicas, Programa de Pós-Graduação em Engenharia Agrícola, 2021.

1. Agricultura de precisão. 2. Índices de vegetação. 3. Plataforma web. 4. Zonas de manejo. I. Mercante, Erivelto. II. Godoy de Souza, Eduardo. III. Título.

## GIUVANE CONTI

Aplicação Computacional AGDATABOX-SR: Gerenciamento de Dados de  
Sensoriamento Remoto

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:




Orientador(a) - Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)




Claudio Leones Bazzi

Universidade Tecnológica Federal do Paraná (UTFPR)




Marcio Furlan Maggi

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)



Davi Marcondes Rocha

Universidade Tecnológica Federal do Paraná (UTFPR)



Marcio Antonio Vilas Boas

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 19 de fevereiro de 2021.

## BIOGRAFIA

Giuvane Conti, nascido no dia 26 de julho de 1984 na cidade de Medianeira, PR. Residente em Santa Helena. Filho de Ivanir Terezinha Conti e Divo Conti. No ano de 2010 concluiu o curso de Tecnologia em Análise e Desenvolvimento de Sistemas de Informação na Universidade Tecnológica Federal do Paraná – *campus* Medianeira, trabalhou como analista de sistemas e programador de 2010 a 2014. Iniciou em 2014 o curso de Pós-Graduação em Computação Aplicada, em nível de mestrado, na Universidade Estadual de Ponta Grossa como bolsista CAPES. Em 2016, ingressou como professor do magistério superior, do curso de Bacharelado em Ciências da Computação na Universidade Tecnológica Federal do Paraná – *campus* de Santa Helena. Em 2017, iniciou no Programa de Pós-Graduação em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, em nível de doutorado.

# APLICAÇÃO COMPUTACIONAL AGDATABOX-RS: GERENCIAMENTO DE DADOS DE SENSORIAMENTO REMOTO

## RESUMO

O sensoriamento remoto tem a capacidade de auxiliar na evolução das práticas agrícolas, fornecendo informações periódicas sobre o estado de uma cultura ao longo de uma safra, em diferentes escalas e para diferentes segmentos. Aplicações em agricultura de precisão utilizam práticas de sensoriamento remoto, como os índices de vegetação, derivados de imagens multiespectrais, para mensurar parâmetros físicos e químicos das plantas, no decorrer do seu ciclo de desenvolvimento. Os avanços tecnológicos oportunizaram o desenvolvimento de serviços inovadores para o setor agrícola, baseados na internet e hospedados em nuvem. Sendo assim, o objetivo dessa pesquisa foi desenvolver uma aplicação computacional que integre e forneça dados de sensoriamento remoto para a plataforma de agricultura de precisão AgDataBox. A aplicação desenvolvida permite o cadastro de uma nova área (talhão), buscar imagens raster de satélites orbitais, selecionar índices de vegetação, vetorizar e inserir as imagens de interesse na plataforma AgDataBox. A aplicação proposta foi testada com dados da safra de milho de 2018/201 (safra verão), em uma área de estudo no município de Céu Azul, Paraná. Foram gerados 12 vetores a partir de imagens do satélite *Sentinel-2*, utilizando o índice de vegetação por diferença normalizada (NDVI), índice de vegetação melhorado (EVI) e índice de vegetação melhorado 2 (EVI-2) dos dias 11/12/2018, 16/12/2018, 15/01/2019 e 25/01/2019 e inseridos na plataforma AgDataBox. Também foram inseridos vetores com variáveis de produtividade, altitude, areia, silte, argila, resistência mecânica a penetração do solo nas profundidades de 0-0,1 m, 0-0,2 m, 0,1-0,2 m e 0,2-0,3 m. Após a análise de autocorrelação entre as variáveis, tendo produtividade como variável alvo, foram selecionadas EVI2 e altitude como as variáveis que apresentaram melhor autocorrelação cruzada com a variável alvo. Foram delineadas zonas de manejo (ZMs) no módulo AgDataBox-Map, utilizando o método *fuzzy c-means*, para duas, três e quatro classes utilizando três conjuntos de variáveis de entrada: (i) EVI-2\_NM, (ii) Altitude, e (iii) EVI 2\_NM+Altitude. Após análise dos resultados, conclui-se que o melhor delineamento utilizou a variável EVI-2 no delineamento de três classes de ZMs. Todos os delineamentos para duas classes apresentaram diferença estatística entre suas classes, sendo o melhor desempenho obtido com a variável altitude. Todos os delineamentos com quatro classes foram descartados, pois não apresentaram diferença estatística significativa entre suas classes.

**PALAVRAS-CHAVE:** agricultura de precisão, índices de vegetação, plataforma web, zonas de manejo.

# COMPUTATIONAL APPLICATION AGDATABOX-RS: REMOTE SENSING DATA MANAGEMENT

## ABSTRACT

Remote sensing has the ability to assist in the evolution of agricultural practices, providing periodic information about the state of a crop over a harvest, at different scales and for different segments. Applications in precision agriculture use remote sensing practices, such as vegetation indexes, from multispectral images, to measure physical and chemical parameters of plants, along their development cycle. Technological advances allowed the development of innovative services for the agricultural sector, based on the internet and hosted in the cloud. Therefore, the objective of this research was to develop a computational module that integrates and provides remote sensing data for the AgDataBox precision agriculture platform. The developed application allows the persistence of a new area (field), the search for raster images of orbital satellites, the selection vegetation indexes, as well as vectorizing and inserting images of interest in the AgDataBox platform. The proposed module was tested with data from the 2018/2019 corn crop (summer harvest), in a study area at Céu Azul, Paraná. Twelve vectors were generated from Sentinel-2 satellite images, using the normalized difference vegetation index (NDVI), enhanced vegetation index (EVI) and enhanced vegetation index (EVI-2) of 11/12/2018, 12/16/2018, 15/01/2019 and 25/01/2019 and persisted in the AgDataBox platform. In addition, vectors were persisted with variables of productivity, altitude, sand, silt, clay, mechanical resistance to soil penetration at depths of 0-0.1, 0-0.2, 0.1-0.2, and 0.2-2.3 m. After autocorrelation analysis between the variables, with productivity as the target variable, EVI-2 and altitude were selected as the variables that showed the best cross autocorrelation with the target variable. Management zones (MZs) were delineated in the AgDataBox-Map module, using the fuzzy c-means method, for two, three, and four classes using three sets of input variables: (i) EVI-2\_NM, (ii) Altitude, and (iii) EVI 2\_NM + Altitude. After analyzing the results, it was concluded that the best design used the variable EVI-2 in the design of three classes of MZs. All designs for two classes showed statistical differences between their classes, with the best performance being obtained with the altitude variable. All designs with four classes were discarded, as there was no statistically significant difference between their classes.

**KEYWORDS:** precision agriculture, management zones, vegetation indexes, web platform.

## SUMÁRIO

<b>LISTA DE FIGURAS .....</b>	<b>viii</b>
<b>LISTA DE TABELAS.....</b>	<b>ix</b>
<b>LISTA DE ABREVIATURAS E SIGLAS.....</b>	<b>x</b>
<b>1 INTRODUÇÃO .....</b>	<b>1</b>
<b>2 OBJETIVOS.....</b>	<b>3</b>
2.1 Objetivo geral .....	3
2.2 Objetivos específicos.....	3
<b>3 REVISÃO BIBLIOGRÁFICA .....</b>	<b>4</b>
3.1 Geoprocessamento e sistema de informações geográficas (SIG) .....	4
3.1.1 Modelo matricial ( <i>raster</i> ).....	5
3.1.2 Modelo vetorial .....	6
3.2 Sensoriamento remoto (SR) .....	8
3.2.1 Sensoriamento remoto na agricultura .....	11
3.2.2 Índices de vegetação e agricultura de precisão .....	12
3.2.3 Computação em nuvem e sensoriamento remoto .....	17
3.3 Processamento digital de imagens (PDI).....	19
3.4 Ferramentas (bibliotecas) para manipulação de dados espaciais.....	22
<b>4 MATERIAL E MÉTODOS.....</b>	<b>24</b>
4.1 <i>Softwares</i> e tecnologias utilizadas.....	24
4.2 Área de estudo .....	24
4.3 Plataforma AgDataBox (ADB) .....	25
4.3.1 Visão geral .....	25
4.3.2 Aplicação AgDataBox - sensoriamento remoto (ADB-RS).....	27
<b>5 RESULTADOS E DISCUSSÃO .....</b>	<b>37</b>
<b>6 CONSIDERAÇÕES FINAIS .....</b>	<b>48</b>
6.1 Conclusões .....	48
6.2 Trabalhos futuros .....	49
<b>REFERÊNCIAS .....</b>	<b>50</b>
<b>APÊNDICES.....</b>	<b>57</b>

<b>APÊNDICE A</b>	<b>INTERFACE DE LISTAGEM DE ÁREAS CADASTRADAS .....</b>	<b>58</b>
<b>APÊNDICE B</b>	<b>INTERFACE DE BUSCA DE IMAGENS DE SATÉLITE E IVS .....</b>	<b>59</b>
<b>APÊNDICE C</b>	<b>INTERFACE DE BUSCA DE IMAGENS DE SATÉLITE .....</b>	<b>60</b>

## LISTA DE FIGURAS

<b>Figura 1</b>	Estrutura matricial ( <i>raster</i> ). Imagem do sensor TM/ <i>Landsat</i> e mapa temático de altimetria.....	6
<b>Figura 2</b>	Representações vetoriais em duas dimensões.....	6
<b>Figura 3</b>	Estrutura de armazenamento de dados para linha.....	7
<b>Figura 4</b>	Esquema das diferentes maneiras de extrair informações ao longo da safra.....	12
<b>Figura 5</b>	Perfil temporal de EVI, extraído a cada 8 dias para estimar a produtividade de lavouras, identificadas como semeadura, pico vegetativo e colheita. ....	15
<b>Figura 6</b>	Etapas de um sistema de processamento digital de imagens.....	20
<b>Figura 7</b>	Área de estudo, em Céu Azul, Paraná.....	25
<b>Figura 8</b>	Arquitetura da plataforma AgDataBox (ADB).....	26
<b>Figura 9</b>	Comunicação entre AgDataBox API e serviços. ....	27
<b>Figura 10</b>	Estrutura da aplicação AgDataBox-RS que irá compor a plataforma AgDataBox. ....	28
<b>Figura 11</b>	Funcionalidades da plataforma ADB-RS apresentadas de forma detalhada.....	29
<b>Figura 12</b>	Paletas de cores para serem utilizadas na apresentação de imagens <i>raster</i> do tipo IVs.....	30
<b>Figura 13</b>	Diagrama de atividades da aplicação ADB-RS.....	31
<b>Figura 14</b>	Pontos de coleta dos dados amostrais. ....	32
<b>Figura 15</b>	Metodologia utilizada para o delineamento de zonas de manejo. ....	32
<b>Figura 16</b>	Interface de busca de imagens para talhões do ADB-SR. ....	37
<b>Figura 17</b>	Comparativo de IVs do cultivo de milho da safra 2018/2019.....	38
<b>Figura 18</b>	Valores médios dos índices NDVI, EVI e EVI-2 para todo o período fenológico da Safra 2018-2019.....	39
<b>Figura 19</b>	Vetorização de imagens do formato <i>raster</i> para o padrão JSON. ....	41
<b>Figura 20</b>	Vetor de NDVI, EVI e EVI2 de médias normalizado.....	41
<b>Figura 21</b>	Mapa de interpolação por IDW aplicado dos vetores <b>a)</b> EVI2_NORMAL_MÉDIO; <b>b)</b> Produtividade; <b>c)</b> Altitude. ....	44
<b>Figura 22</b>	Zonas de manejo originais e retificadas, com duas, três e quatro classes, utilizando três conjuntos de variáveis de entrada: (a) EVI-2. (b) Altitude. (c) EVI-2+Altitude. ....	44
<b>Figura 23</b>	Valores de dispersão para Altitude, EVI-2 e EVI2 e Altitude. <b>a)</b> VR para 2, 3 e 4 classes de ZMs; <b>b)</b> GQI para 2, 3 e 4 classes e <b>c)</b> ICVI para 2, 3 e 4 classes...	47

## LISTA DE TABELAS

<b>Tabela 1</b>	Bibliotecas para auxílio de implementação de <i>softwares</i> geoespaciais.....	22
<b>Tabela 2</b>	Parâmetros retornados no formato JSON em um acesso HTTP .....	31
<b>Tabela 3</b>	Valores estatísticos de IVs para imagens no intervalo dos meses de novembro/2018, dezembro/2018, janeiro/2019, fevereiro/2019 e março/2019...	40
<b>Tabela 4</b>	Resumo estatístico das variáveis.....	42
<b>Tabela 5</b>	Matriz de correlação espacial, apresentando os valores de autocorrelação espacial e correlação espacial cruzada .....	42
<b>Tabela 6</b>	Processo de seleção de variáveis a serem utilizadas no delineamento de zonas de manejo.....	43
<b>Tabela 7</b>	Análise estatística de avaliação das ZMs geradas.....	45
<b>Tabela 8</b>	Comparação de índices de concordância (Kappa) entre as ZMs.....	46

## LISTA DE ABREVIATURAS E SIGLAS

ADB	Plataforma AgDataBox
AP	Agricultura de precisão
API	Application programming interface
DSWI	Disease water stress index
EVI	Enhanced vegetation Index
FI	Fragmentation index
FPI	Fuzziness performance index
GNSS	Global navigation satellite systems
GQI	Global quality index
ICVI	Improved cluster validation index
IDE	Integrated development environment
IFOV	Instantaneous field of view
IV	Índice de vegetação
JSON	JavaScript object notation
LAI	Leaf area index
LSWI	Land surface water index
MPE	Modified partition entropy
MWIR	Index of refraction of moist air
NDVI	Normalized difference vegetation index
NDWI	Normalized difference water index
NIR	Near infra-red
NRI	Nitrogen reflectance index
OGC	The open geospatial consortium
PDI	Processamento digital de imagens
REM	Radiação eletromagnética
REST	Representational state transfer
RGB	Red, green, blue
RSP	Resistência mecânica à penetração
SAVI	Vegetation index soil-adjusted
SI	Smoothness index
SIG	Sistema de informações geográficas
SR	Sensoriamento remoto
TIR	thermal infra-red
UML	Unified modeling language
VANT	Veículo aéreo não tripulado
VIS	Bandas do visível
VR	Variance reduction
WPS	Web processing service
ZM	Zona de manejo

## 1 INTRODUÇÃO

A aplicação de novas tecnologias abre caminho para o desenvolvimento de novos modelos de negócio e serviços para o setor agrícola e agroindustrial. A agricultura de precisão (AP) e a Agricultura 4.0 (ou agricultura digital) podem ser descritas como um conjunto de sistemas de apoio à decisão, empregando tecnologias para gerenciar a variabilidade espacial e temporal em cada unidade de colheita, para melhorar a produtividade das culturas e, ao mesmo tempo, diminuir o impacto ambiental.

Os avanços nas técnicas de sensoriamento remoto (SR) permitem o uso de imagens multiespectrais como ferramentas eficazes na determinação e monitoramento das condições da vegetação, estresse da cultura e previsão de produtividade (AL-GAADI et al., 2016). O sensoriamento remoto é uma ferramenta importante, pois fornece dados espaciais e temporais para gerenciar talhões agrícolas de forma rápida e econômica.

A combinação do SR e AP contribuem para o avanço do setor agrícola. Um exemplo do resultado dessa associação é que muitas aplicações em AP usam índices de vegetação (IVs) para monitorar culturas e estimar sua produtividade. Com o auxílio de IVs é possível obter as características sazonais do crescimento da vegetação e sua fenologia, como o início e o fim do período de crescimento, a data do pico vegetativo e variações na folhagem verde das plantas.

Na AP se recomenda o uso de técnicas e tecnologias como Sistema Global de Navegação por Satélite (*Global Navigation Satellite Systems - GNSS*), grades amostrais densas, monitoramento instantâneo de variáveis do solo e de plantas, mapeamento das variabilidades espacial e temporal dessas variáveis, aplicação de insumos a taxas variáveis e gerenciamento de dados. O SR é uma ferramenta importante da agricultura digital na identificação da variabilidade espacial em talhões.

Com o crescimento contínuo de dados de sensoriamento remoto, abordagens baseadas em *desktop* foram complementadas por estruturas virtuais de armazenagem de dados denominadas como nuvem. A computação em nuvem oferece avanços tecnológicos para o setor, pelo desenvolvimento de sistemas baseados na rede mundial de computadores denominada *internet* (KALOXYLOS et al., 2014), reduzindo o custo computacional apresentado pelos modelos tradicionais de sensoriamento remoto e satisfazendo o problema do requisito de tempo, em aplicações que tratam de monitoramentos dinâmicos. Um desafio é a criação de ferramentas que apresentem interoperabilidade geoespacial, manipulação de grandes volumes de dados e distribuição de seus recursos através da *World Wide Web*.

A implementação de análise geoespacial e armazenamento de dados em nuvem pode solucionar o problema de incompatibilidade entre plataformas e ferramentas na área de sensoriamento remoto e agricultura de precisão. Muitas soluções nesses segmentos são utilizadas de maneira isolada (TANG; MATYAS, 2018).

No entanto, a taxa de adoção da AP tem sido lenta entre os pequenos agricultores. Isso se deve aos altos custos empregados para sua implantação e manutenção. Uma opção é a divisão de áreas produtivas em zonas de manejo (ZMs). Essa prática que pode viabilizar a aplicação de AP para mais produtores. Cada ZM é uma subárea com características similares e que pode ser tratada como área homogênea. O uso de ZMs possibilita reduzir a quantidade de amostras coletadas e analisadas.

Diante disso, considerou-se importante desenvolver uma aplicação computacional que forneça dados de imagens orbitais e IVs para serem utilizados como variáveis candidatas ao delineamento de ZMs e que possam auxiliar a avaliação da produtividade em talhões. Além disso, propôs-se que a aplicação computacional desenvolvida apresentasse interoperabilidade, possibilidade de manipular grandes volumes de dados e distribuísse seus recursos através da internet, de forma padronizada.

## 2 OBJETIVOS

### 2.1 Objetivo geral

Desenvolver uma aplicação computacional (ADB-RS) para a plataforma *web* AgDataBox (ADB), que gere vetores de dados a partir de imagens dos satélites *Landsat-8* e *Sentinel-2*, que possam ser utilizados para a geração de zonas de manejo.

### 2.2 Objetivos específicos

- 1 Modelar e desenvolver a arquitetura de *backend* e *frontend* da aplicação ADB-RS;
- 2 Integrar a aplicação com a *Application Programming Interface* (API) de sensoriamento remoto, que fornece imagens de satélites via comunicação HTTP *Representational State Transfer* (REST);
- 3 Selecionar uma biblioteca geoespacial de manipulação de imagens *raster* e implementar algoritmos que transformem as imagens de interesse em vetores de dados;
- 4 Gerar vetores de dados, seguindo a padronização da plataforma ADB, para as imagens de satélite selecionadas;
- 5 Integrar a aplicação desenvolvida (ADB-RS) com a plataforma ADB e realizar o delineamento de zonas de manejo na aplicação ADB-Map, com os vetores de dados gerados na aplicação ADB-RS.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 Geoprocessamento e sistema de informações geográficas (SIG)

O geoprocessamento é um conjunto de tecnologias que coletam e tratam informações espaciais para um objetivo específico e tem sido empregado em áreas como cartografia, geografia, agricultura, florestas, geologia, planejamento urbano e rural, meios de transporte, comunicação e energia (CÂMARA et al., 2001).

Um Sistema de Informações Geográficas (SIGs) trata um número infinito de informações de procedência geográfica. O desenvolvimento dos SIGs se deve à evolução do *hardware* e *software* na resolução de problemas. Sendo assim, além do uso do meio computacional, é necessário ter uma base de dados georreferenciada, associada a um sistema de coordenadas conhecido, vinculando pontos reais dispostos no terreno, usualmente caracterizados por sua latitude e longitude. Pode-se definir SIG como um sistema constituído por programas computacionais, que integram dados, equipamentos e pessoas, tendo como objetivo coletar, armazenar, recuperar, manipular, visualizar e analisar dados espacialmente referenciados a um sistema de coordenadas conhecido (FITZ, 2008).

Em muitos casos, o termo SIG é confundido com geoprocessamento. O geoprocessamento trata de um conceito mais abrangente e representa qualquer forma de processamento de dados georreferenciados, já o SIG processa dados gráficos e não-gráficos (alfanuméricos), dando maior ênfase para análises espaciais e modelagens de superfícies (BURROUGH, 1987).

A tecnologia SIG é utilizada em vários setores e é tida como importante ferramenta para o planejamento ambiental. Com um SIG é possível avaliar grande número de variáveis de forma simplificada, gerar informações e trabalhar com variáveis anteriormente não pensadas (DONHA; SOUZA; SUGAMOSTO, 2006).

Devido ao grande número de aplicações, há pelo menos três grandes formas de se utilizar um SIG: i) como ferramenta de produção de mapas; ii) como suporte para análise espacial de fenômenos; iii) como um banco de dados geográfico, com funções de armazenamento e recuperação de informação espacial. O SIG separa a informação em camadas temáticas e as armazena de forma independente. Também permite ao usuário relacionar a informação existente por meio de sua posição e topologia, com o intuito de gerar nova informação (MOREIRA, 2011; MENEZES et al., 2017).

Um SIG é constituído por *hardware*, *software*, dados e pessoas. Produtos gerados por SIGs, devidamente mapeados, apresentam potencial para o conhecimento aprofundado de uma região, com a possibilidade de tomada de decisão amparada por um processo decisório consistente. O sucesso de uma aplicação depende das necessidades do usuário e da disponibilidade de recursos para aquisição e manutenção (FITZ, 2008).

As representações de modelos geométricos para representar componentes gráficos mais comuns em SIG são os modelos *raster* ou matricial e o vetorial (MOREIRA, 2011).


### 3.1.1 Modelo matricial (*raster*)

Na representação pelo modelo *raster*, a área é dividida em uma grade regular de células, cada célula representa sua linha e coluna. Cada célula armazena um tipo de entidade, de acordo com o que é encontrado naquela posição. Uma área é representada por camadas e suas células armazenam valores associados a uma única variável (ex.: solo, hidrologia, relevo). Cada localização da área de estudo corresponde a uma célula no modelo matricial (LISBOA FILHO; IOCHPE, 1996).

A cada célula é atribuído um código que representa o atributo estudado, para que o computador identifique a que elemento ou objeto pertence determinada célula. O espaço é representado como uma matriz  $P(m,n)$  composta de  $m$  colunas e  $n$  linhas, cada célula é identificada por sua linha e coluna e um valor correspondente ao atributo estudado. Cada célula é acessada individualmente por sua coordenada (CÂMARA, 2005; CÂMARA et al, 2001; QUEIROZ; FERREIRA, 2006).

As células podem conter diferentes tipos de valores (ex.: inteiro, decimal, caractere etc.). Dois conceitos importantes desse processo são a resolução e a orientação do modelo. Resolução representa a dimensão linear mínima da menor unidade do espaço geográfico, ou seja, uma célula. Quanto menor a dimensão das células, maior a resolução da área. A orientação diz respeito ao ângulo entre o norte verdadeiro e a direção das colunas do modelo (LISBOA FILHO; IOCHPE, 1996).

Exemplos importantes do uso da representação matricial ou *raster* são as imagens de satélite, mapas temáticos matriciais (Figura 1).




**Figura 1** Estrutura matricial (*raster*). Imagem do sensor TM/*Landsat* e mapa temático de altimetria.

Fonte: Moreira (2011).

Um espaço celular é representado por uma estrutura matricial e cada célula pode estar associada a vários tipos de atributos. Utilizando matrizes para um único atributo, um fenômeno espaço-temporal complexo necessita de muitas matrizes para ser representado. Toda a estrutura de um espaço celular pode ser armazenada em uma tabela, assim, aplicações como álgebra de mapas e modelagem dinâmica ficam mais simples para serem implementados (CÂMARA, 2005; QUEIROZ; FERREIRA, 2006).

### 3.1.2 Modelo vetorial

No modelo vetorial, as entidades são representadas como pontos, linhas e polígonos. A posição dos objetos é baseada em sua localização no espaço, ligada a um sistema de coordenadas conhecido. A primitiva principal do modelo vetorial é o ponto, porém, são utilizados três construtores básicos (Figura 2): ponto, linha e polígono (LISBOA FILHO; IOCHPE, 1996).




**Figura 2** Representações vetoriais em duas dimensões.

Fonte: Câmara, (2005); Queiroz e Ferreira (2006).

Um ponto possui coordenadas espaciais  $x$  e  $y$  e pode ser utilizado para representar a localização de crimes, ocorrência de doenças, localização de espécies vegetais etc. Uma linha é um conjunto de pontos, utilizada para armazenar feições unidimensionais. Um polígono é uma região limitada por um ou mais linhas poligonais conectadas, sendo o primeiro ponto que representa o polígono idêntico ao seu último ponto (CÂMARA, 2005; QUEIROZ; FERREIRA, 2006).

A estrutura de dados para armazenamento de pontos adiciona as coordenadas  $x$  e  $y$  como dois atributos extras na tabela de atributos (não espaciais) que descrevem entidades. Um objeto espacial do tipo ponto pode possuir muitos atributos associados em sua representação (LISBOA FILHO; IOCHPE, 1996).

Estruturas de armazenamento de linhas mantêm seus relacionamentos entre objetos lineares. Consistem em dois tipos de objetos espaciais: linhas (ligações, arestas ou arcos) e pontos (nós, interseções ou junções). Um exemplo de estrutura em linha, no formato rede, composta de 4 nós e 5 arcos pode ser vista na Figura 3.



**Figura 3** Estrutura de armazenamento de dados para linha.

**Fonte:** Lisboa Filho e Iochpe (1996).

Para uma estrutura de dados para armazenar polígonos o relacionamento entre entidades bidimensionais (áreas) é representado por dados que apresenta estruturas com informações sobre polígonos adjacentes (LISBOA FILHO; IOCHPE, 1996).

### 3.2 Sensoriamento remoto (SR)

Sensoriamento Remoto (SR) é a tecnologia que permite a obtenção de dados da superfície terrestre, pela captação do registro da energia refletida ou emitida pela superfície (MENEZES et al., 2017; HUYLENBROECK et al, 2020). O termo sensoriamento refere-se a sensores instalados em plataformas terrestres, aéreas e orbitais. O termo remoto, significa que a obtenção é realizada a distância, ou seja, sem contato físico (MENEZES et al., 2017). Os recursos do sensor/plataforma definem suas capacidades espectrais, direcionais, resolução espacial e as frequências de revisita ao mesmo local (WEISS; JACOB; DUVEILLER, 2020).

O campo de sensoriamento remoto representa a convergência de conhecimento de duas áreas. Os avanços no campo de aerofotogrametria e fotointerpretação, a pesquisa espacial e os avanços tecnológicos em novos sensores baseados em fotodetectores possibilitam a obtenção de informações da superfície terrestre não apenas por meio de aviões, mas sim de satélites (MENEZES et al., 2017).

Os sensores podem ser classificados de forma diferenciada, com relação à origem da fonte de energia. Sensores ativos são aqueles que possuem fonte de energia própria, eles emitem uma quantidade suficiente de energia na direção de alvos para capturar sua reflexão. Os sensores passivos não possuem fonte própria de energia e dependem de fontes externas para captar a reflexão de alvos, como por exemplo, a energia solar (MENEZES et al., 2017). Outra forma de classificação é feita em função do produto gerado. Sendo assim, existem os sensores imageadores, que traduzem a coleta em forma de imagem, e os não imageadores, que traduzem a coleta em forma de gráficos e dados digitais diversos (FITZ, 2008).

Sistemas de SR fornecem dados repetitivos e consistentes da superfície da Terra e podem ser aplicados nas seguintes áreas: planejamento urbano; agrícola; geológica; ecológica; florestal; cartográfica; oceanográfica; hidrológica; limnológica e militar. Cada uma dessas aplicações tem frequência de revisita, resolução espacial, espectral e radiométrica. Esses requisitos necessitam ser ajustados aos diferentes dados disponíveis. (MORAES NOVO, 2010).

A Terra recebe energia do sol, parte é absorvida e outra parte é refletida. A radiação solar incidente na superfície terrestre refletida pode ser capturada por sensores acoplados em satélites artificiais que estão em órbita. A radiação solar é do tipo eletromagnética (REM) que possui ondas com diversas características físicas. O sol é a mais importante fonte de REM (FITZ, 2008).

A REM se propaga em forma de ondas, apresentando velocidade, frequência e comprimento de onda. A distribuição da REM é representada pelo espectro eletromagnético,

pelo seu comprimento e frequência, desde curtos comprimentos de onda, como os raios cósmicos e os raios gama, de alta frequência, até longos comprimentos de onda, como as ondas de rádio e TV, de baixa frequência. Na região do espectro visível, o olho humano identifica a energia (luz) eletromagnética, distinguindo do violeta ao vermelho. Já a radiação do infravermelho subdivide-se em: infravermelho próximo (0,7-1,3 micrômetros); médio (1,0-6,0 micrômetros); e distante ou termal (6,0-1.000 micrômetros). É possível obter imagens de uma mesma área, em diferentes faixas espectrais, também denominadas de canais ou bandas (FLORENZANO, 2011).

Independentemente do tipo, o sensor é caracterizado por elementos que indicam ao usuário o que ele pode esperar dos dados coletados. Essas características podem ser classificadas em: geométricas, espectrais e radiométricas. Características geométricas definem a qualidade da imagem adquirida. Características radiométricas indicam a capacidade do sensor de identificar objetos na cena, em função das diferentes energias refletidas e emitidas. Características espectrais indicam regiões do espectro eletromagnético no qual o sensor opera (MORAES NOVO, 2010).

A resolução espacial representa a distinção da menor feição possível de detecção realizada pelo sensor, possuindo um campo de visada do sensor (*Field of view* - FOV) e um campo de visada instantânea (*Instantaneous field of view* - IFOV) que determina a área da superfície terrestre que é “vista” pelo sensor. A área vista pelo IFOV é chamada de elemento de resolução do terreno. Para ser identificado, ele precisa necessariamente ter suas dimensões iguais ou maiores que o elemento de resolução do terreno. Imagens de SR são formadas por matrizes de elementos de imagem (*picture element*) ou *pixels* (MORAES NOVO, 2010). Observa-se na Equação 1 a relação entre as variáveis que definem a resolução do elemento no terreno (D), em metros (FORMAGGIO; SANCHES, 2017). Avanços nos sensores de satélite melhoraram muito a resolução espacial de imagens (YANG, 2020).

$$D = H \beta \quad (1)$$

Em que

- H = altitude do sensor (m);
- $\beta$  = ângulo (ifov) (miliradianos).

A resolução espectral é uma medida da largura das faixas espectrais e da sensibilidade do sensor. Um sensor que opera na faixa de 0,4 e 0,5 micrômetros tem sua resolução espectral maior que um que opera na faixa de 0,4 e 0,6. Este será capaz de registrar variações no comportamento espectral em regiões mais estreitas do espectro eletromagnético. Sensores com melhor resolução espectral podem aumentar o número de bandas (faixas de captura) para a análise da REM e os materiais da superfície terrestre (FLORENZANO, 2011).

A resolução radiométrica é descrita como a habilidade de um sensor em distinguir variações no nível da energia refletida, emitida ou retroespalhada que deixa a superfície do alvo. Esta apresenta diferenças de intensidade contínuas, sendo necessário que o sensor as detecte, registre e reproduza. Quanto maior a capacidade do sensor em distinguir essa intensidade do sinal, maior sua resolução radiométrica. A calibração radiométrica é outro fator importante que determina a precisão espectral e derivados baseados em reflectância (DENG et al., 2018).

A resolução temporal se refere ao espaço de tempo que o sensor leva para a obtenção de cada cena. O sensor brasileiro Cbers-2 captura imagens de uma mesma cena de 26 em 26 dias, sendo assim, sua resolução temporal é de 26 dias (FITZ, 2008). Já o sensor *Sentinel-2* possui uma resolução espacial de 10 metros e tempo de revisita de 5 dias (SPADONI et al., 2020).

Os níveis de aquisição de dados em SR estão ligados ao veículo ou sistema de suporte para a operação do sensor, este recebe o nome de plataforma. As plataformas mais comuns são satélites e aeronaves. A seleção da plataforma depende do objetivo para o qual os dados são adquiridos. Muitas vezes, dados adquiridos por aeronaves são utilizados para identificar alvos em classes espectrais as quais não foram identificadas em imagens orbitais ou que são de informações específicas da área (MORAES NOVO, 2010).

No nível orbital, existem quatro segmentos tecnológicos que determinam a evolução do SR: a) desenvolvimento dos veículos lançadores de satélites: foguetes que colocam em órbita o satélite; b) desenvolvimento dos sistemas sensores: responsáveis por identificar a radiação em dada faixa do espectro eletromagnético e registrá-la para interpretação; c) sistema de telemetria: metodologia que permite transmitir os dados coletados pelos sensores para estações terrestres; d) sistemas de processamento: equipamentos computacionais e *softwares* destinados ao armazenamento e processamento dos dados coletados (MOREIRA, 2011).

Os primeiros sensores fotográficos criados eram pancromáticos, isto é, toda energia vinda do alvo era integrada em todos os comprimentos de onda. Assim, muitas informações específicas sobre a interação do objeto, em um determinado comprimento de onda, eram perdidas. Nesse momento, surgiu a ideia de se obterem imagens simultâneas de uma mesma cena, em várias regiões do espectro, surgindo os sensores multiespectrais. A maioria dos sensores multiespectrais trabalham com as bandas no visível (VIS), infravermelho próximo (NIR), infravermelho de ondas curtas (MWIR) e infravermelho termal (TIR) (FLORENZANO, 2011).

Os sensores hiperespectrais surgidos na década de 1980 são uma evolução da tecnologia multiespectral que possibilita obter imagens em centenas de bandas estreitas (FORMAGGIO; SANCHES, 2017).

### 3.2.1 Sensoriamento remoto na agricultura


Os avanços no SR têm potencializado o processo de monitoramento do desenvolvimento das culturas agrícolas e estimativas de sua produtividade (AL-GAADI et al., 2016). Dados multiespectrais são de grande utilidade para os objetivos do SR na agricultura. Dados hiperespectrais possibilitam extrair espectros contínuos de cada *pixel*, auxiliando na extração de informações da composição química dos materiais da superfície terrestre. Dados ultraespectrais possibilitam extrair informações extremamente detalhadas sobre os alvos. Para o uso de imagens de SR em aplicações agrícolas, é importante uma alta frequência temporal, que cubra todo o ciclo agrícola (FORMAGGIO; SANCHES, 2017).

Sensores ópticos são utilizados para detectar mudanças na vegetação, a resolução espacial é um fator importante a ser considerado, pois sensores de alta resolução espacial, geralmente, são capazes de detectar mudanças na vegetação com maior precisão (CHEN et al., 2019; WEISS; JACOB; DUVEILLER, 2020).

Nas principais regiões produtoras brasileiras, o período de primavera-verão ocorre em uma época em que há alta incidência de chuvas, resultando em alta probabilidade de nuvens nas imagens. A revisita temporal é importante para o SR de culturas agrícolas, principalmente as de verão, pois quanto maior o índice de repetição, maior a chance de se obter imagens sem restrições de nuvens (FORMAGGIO; SANCHES, 2017).

O monitoramento em tempo real é necessário para reagir a eventos externos, como alterações climáticas e otimizar práticas de gestão de forma sustentável. O SR aparece como ferramenta essencial para cumprir esses requisitos, pois fornece informações recorrentes em escala local e global de forma sistemática, possibilitando a caracterização da variabilidade espaço-temporal dentro de uma determinada área (WEISS, JACOB; DUVEILLER, 2020). O SR tem sido reconhecido como uma forma econômica para se detectar a variabilidade espacial e temporal no crescimento e produtividade de culturas (BREUNIG et al, 2020; CICORE et al, 2016; DAMIAN et al, 2020; DONG et al., 2019).

Observa-se na Figura 4 um esquema dos diferentes modos de extração de informações espaciais para a agricultura.



**Figura 4** Esquema das diferentes maneiras de extrair informações ao longo da safra.

**Fonte:** Adaptado de Maes e Steppe (2019).

Na Figura 4 são destacadas as plataformas e sensores úteis ao longo de uma estação de crescimento de uma safra. Nota-se a contribuição dos veículos aéreos não tripulados (VANTs) no complemento ao monitoramento de todo o processo desde o plantio até a colheita. Imagens *Red Green Blue* (RGB) são indicadas para uso em detecção de pragas e acamamento de culturas. Imagens multiespectrais são indicadas para avaliar o estado nutricional das plantas e previsão da produtividade da safra. Imagens hiperespectrais são indicadas para detecção de pragas e patógenos. Imagens termais são indicadas para detecção de patógenos e estresse hídricos (MAES; STEPPE, 2019). Para indicar o estado nutricional das plantas e a previsão da produtividade de uma safra, geralmente são utilizadas imagens multiespectrais, com o auxílio de índices de vegetação (IVs).

### 3.2.2 Índices de vegetação e agricultura de precisão

A agricultura conta com técnicas avançadas de SR para evitar a perda de recursos naturais em áreas de interesse. Nesse sentido, o uso de sensores ópticos permite a avaliação de parâmetros biológicos ligados à densidade da biomassa, à concentração de clorofila, à eficiência do sistema fotossintético, ao processo de evapotranspiração e ao estresse abiótico ou biótico (SEMERARO et al., 2019). Técnicas de SR aprimoraram o uso de imagens multiespectrais como uma ferramenta eficaz na determinação e monitoramento das condições da vegetação, estresse da cultura e previsão de sua produtividade (AL-GAADI et al., 2016).

Os índices de vegetação (IVs) têm por base formulações matemáticas aplicadas em dados espectrais de sensores. Para utilizar IVs, é fundamental que os sensores utilizados forneçam as bandas do vermelho e do infravermelho próximo (FORMAGGIO; SANCHES, 2017). É possível capturar as características sazonais do crescimento da vegetação e sua mudança fenológica, como o início e o final da estação de crescimento e a data do pico de biomassa. Os IVs têm se tornado um importante indicador na descrição das mudanças climáticas globais e seu impacto em ecossistemas, sendo utilizados na classificação de cobertura da Terra, identificação de mudanças ambientais, no monitoramento de safras, na identificação da fração da radiação fotossinteticamente ativa, no conteúdo de água, presença de componentes químicos e características biofísicas (FORMAGGIO; SANCHES, 2017; SEMERARO et al., 2019; SUN et al., 2021).

Na AP esses índices podem ser utilizados para analisar a variabilidade espacial de plantas em talhões, servindo de base para um manejo otimizado e sustentável (FORMAGGIO; SANCHES, 2017). No geral, a simplicidade e a fácil interpretação constituem as principais vantagens dos IVs. Com o auxílio de IVs é possível avaliar a dinâmica da vegetação ao longo do tempo e do espaço, pois são indicadores das variações temporais e espaciais da estrutura da vegetação e dos parâmetros biofísicos, facilitando as aplicações relacionadas ao monitoramento agrícola (PÔÇAS et al., 2020). Além disso, a combinação do SR e a AP é uma importante ferramenta na detecção e gerenciamento de doenças em plantações. Os IVs podem ser utilizados para o controle de doenças recorrentes em safras futuras (YANG, 2020).

A AP implica a gestão adequada da variabilidade inerente do solo e das culturas, resultando em aumento dos benefícios econômicos e na redução do impacto ambiental. No entanto, os tratamentos localizados requerem mapas de variabilidade do solo para identificar áreas de terra que compartilham propriedades semelhantes (ARANGO et al., 2017).

A AP pode ser descrita como um conjunto de sistemas de apoio à decisão que buscam gerenciar a variabilidade espacial e temporal a fim de maximizar a produtividade, a qualidade e o lucro das colheitas e melhorar a eficiência do uso dos insumos, minimizando os danos ambientais. O delineamento de zonas de manejo (ZMs) em campos agrícolas representam uma prática importante na AP para apoiar procedimentos como correção do solo, aplicação de herbicidas/fungicidas e redução do impacto ambiental (YOST et al., 2019), além de ser uma abordagem economicamente mais viável para a AP (GAVIOLI et al., 2019).

O Índice de vegetação por diferença normalizada - NDVI (Equação 2) foi proposto por Tucker (1979) e estima a atividade fotossintética por uma combinação de bandas do vermelho (R) e do infravermelho próximo (NIR) que são, geralmente, condicionadas pela presença de clorofila nas plantas (SPADONI et al., 2020; ZHANG et al., 2020).

$$NDVI = \frac{NIR-R}{NIR+R} \quad (2)$$

Em que

$NIR$  = radiação na banda do Infravermelho próximo;  
 $R$  = radiação na banda do vermelho.

O Índice de vegetação melhorado - EVI (Equação 3) é um NDVI modificado, desenvolvido pelo *MODIS Land Discipline Group*, para otimizar o sinal da vegetação com sensibilidade aprimorada em regiões de alta biomassa, através do monitoramento aprimorado da vegetação pelo desacoplamento do sinal de fundo do dossel e redução nas influências da atmosfera (HUETE et al., 2002; PÔÇAS et al., 2020; WANG; GE; LI, 2013). O Índice de vegetação melhorado - EVI-2 (Equação 4), por sua vez, anulou o uso da banda espectral na faixas do azul, com o intuito de fornecer uma referência confiável para avaliar a autocorreção atmosférica, haja vista que essa banda é a mais sensível a essas variações (JIANG et al., 2008).

$$EVI = G \frac{NIR-R}{N+C_1*R-C_2*B+L} \quad (3)$$

Em que

$NIR, R$  e  $B$  = bandas do infravermelho próximo, vermelho e azul;

$G$  = fator de ganho;

$C1$  e  $C2$  = coeficientes do termo de resistência do aerossol, que usam a faixa do azul para corrigir as influências do aerossol na faixa vermelha;

$L$  = fator de ajuste.

$$EVI2 = G \frac{NIR-R}{NIR+(L*R)+1} \quad (4)$$

Em que

$NIR$  e  $R$  = bandas do infravermelho próximo e vermelho;

$G$  = fator de ganho;


$L$  = fator de ajuste.

O NDVI tem sido utilizado como alternativa aos mapas de produtividade, haja vista que está intimamente relacionado à produtividade da cultura (BERTOLIN et al., 2017; CHANG et al., 2014; MAESTRINI; BASSO, 2018; MANN; SCHUMANN; OBREZA, 2011; MUNNAF et al., 2020; TAGARAKIS et al., 2013; VALLENTIN et al., 2020). Com o uso de imagens orbitais é possível mapear grandes áreas com baixo investimento. Avaliar a relação entre as ZMs geradas a partir de mapas de produtividade e as ZMs geradas de IVs é essencial para o aumento da eficiência no delineamento de ZMs (DAMIAN et al., 2020).

Os referidos autores compararam as ZMs geradas com dados de produtividade, com ZM geradas a partir de imagens de satélite. Nesse estudo, os autores citam que a utilização de dados de NDVI pode melhorar tecnicamente o processo de delimitação de ZMs, sugerindo

que o NDVI pode substituir ou complementar os dados de produtividade na delimitação de ZM para sistemas de cultivo anuais.

Son et al. (2014) realizaram um estudo comparativo entre os IVs de EVI e NDVI para estimar a produtividade de culturas. Para isso, os autores criaram uma série temporal para os dados de EVI e NDVI (Figura 5) e selecionaram valores em períodos próximos ao valor máximo (*Heading*) identificado. Ressalta-se que uma cultura, quando atinge o seu pico vegetativo, tem a tendência de apresentar saturação nos valores de IVs.



**Figura 5** Perfil temporal de EVI, extraído a cada 8 dias para estimar a produtividade de lavouras, identificadas como semeadura, pico vegetativo e colheita.

**Nota:** O eixo x representa os dias do ano e o eixo y representa os valores de EVI registrados para o período.

**Fonte:** Adaptado de Son et al. (2014).

Seo et al. (2019) desenvolveram uma abordagem integrativa para monitorar remotamente o crescimento da cultura de milho e soja. Os autores obtiveram ótimos resultados para monitorar a fenologia da cultura, utilizando valores de NDVI do início da safra, do pico da safra e do final da safra, de modo similar ao modelo utilizado por Son et al. (2014) (Figura 5). Sciortino et al. (2020) apresentam uma metodologia baseada em SR para a avaliação rápida da produtividade e monitoramento de *status* e tendências em escalas nacionais e subnacionais. O trabalho foi realizado utilizando NDVI como indicador de produtividade, apresentando ótimos resultados, em um intervalo de 16 anos (2000-2015).

Pesquisas que envolvem AP e IVs têm sido realizadas. Gao et al. (2020) realizaram uma revisão de literatura abrangente e sistemática, de janeiro de 1990 a novembro de 2019,

do uso de IVs em pesquisas na área de SR e constataram que a maioria dos autores utilizou o modelo linear de NDVI. Também identificaram que as imagens utilizadas possuem resolução espacial submétrica e em quilômetro, sendo mais comum o uso de imagens de resolução espacial de 30 metros.

Al-Gaadi et al. (2016) empregaram técnicas de SR para prever a produção de tubérculos de batata. Para isto, utilizaram imagens dos satélites *Landsat-8* e *Sentinel-2* durante as fases de crescimento da cultura e geraram dois IVs a partir das imagens: o NDVI e o índice de vegetação ajustado ao solo (SAVI). Como resultado, os autores destacam que a metodologia desenvolvida é útil para identificar variações na produtividade e ajudará os agricultores e tomadores de decisão no gerenciamento de suas práticas.

Dados de IVs têm sido utilizados com frequência na AP para auxiliar no delineamento de ZMs. Araújo, Vettorazzi e Molin (2005) iniciaram um estudo para utilização do SR como uma possível alternativa para gerar mapas de variabilidade espacial na agricultura e obtiveram resultados promissores. Arango et al. (2017) propuseram um método de baixo custo que combina algoritmos de agrupamento com imagens de satélite. Os autores destacam que o método proposto não exige exploração das parcelas analisadas com nenhum equipamento especial e nem coleta de amostras de solo analisadas em laboratório. O estudo comparou diferentes bandas espectrais e termais do satélite *Landsat-8*, IVs e índices de umidade e apresentou resultados promissores para delineamento de ZMs.

Breunig et al. (2020) investigaram a influência da resolução espacial nas estimativas da cobertura vegetal de centeio, calculadas com base no NDVI e no delineamento subsequente de ZM. Os autores utilizaram imagens de 1, 2, 10 e 30 metros e concluíram que os dados com resolução espacial de 3 metros constituem uma boa alternativa para delinear ZMs para a agricultura familiar no sul do Brasil.

Vallentin et al. (2020) apresentaram um estudo que indica a possibilidade de gerar ZMs combinando informações do solo, estruturas de relevo e o índice de NDVI. Os autores concluíram que todos os dados são igualmente relevantes para a modelagem de classes de rendimento e que a fenologia da planta, sendo medida por meio de imagens de satélite, é importante. Os autores também concluem que as variáveis utilizadas são úteis para serem utilizadas na AP e para o delineamento de ZMs.

Tagarakis et al. (2013) delinearão ZMs usando técnicas de agrupamento *fuzzy* e dados de condutividade elétrica, profundidade do solo, topografia, 5 índices NDVI medidos em diferentes estágios durante o ciclo de crescimento e dados de produtividade para a análise e produção de mapas. Chang et al. (2014) também utilizaram 5 índices NDVI medidos em diferentes estágios durante o ciclo de crescimento da cultura, combinados com dados de produtividade e propriedades do solo para gerar ZMs e concluíram que é viável usar IVs para

delinear ZMs. Ambos os trabalhos utilizaram sensores terrestres para obter o NDVI e se basearam no período fenológico (Figura 5) para definir as datas de coleta.

Os IVs também são utilizados para gerar ZMs que auxiliem na irrigação. Fontanet et al. (2020) utilizaram séries temporais de NDVI do satélite *Sentinel-2* durante todo o período de safra (Figura 5) e medições de umidade do solo, em uma área experimental com milho, para delinear ZMs e realizar irrigação por taxa variável. Como resultado, os autores citam que a integração proposta pode ser usada para apoiar decisões de manejo e reduzir as aplicações de água de 11 a 29%.

Algumas pesquisas sugerem a criação de novos métodos para a geração de IVs. Sun et al. (2021) utilizaram fusão de imagens NDVI e citam que essa tem sido uma solução viável e econômica para aumentar a disponibilidade de dados de alta resolução espacial e temporal. Nesse estudo, foi desenvolvido um novo método para reconstrução do NDVI. Semeraro et al. (2019) analisaram a correlação espacial de alguns índices de vegetação com o dossel do trigo, em vários estágios fenológicos distintos. No primeiro estágio de crescimento, o EVI foi o melhor índice correlacionado ao LAI. No estágio seguinte de crescimento o Índice de Água da Superfície da Terra (LSWI) foi o mais confiável. Baseado nesses resultados, eles desenvolveram um sistema especialista *fuzzy* para combinar o EVI e o LSWI, obtendo um novo índice combinado chamado *Case-specific fuzzy vegetation index*.

### 3.2.3 Computação em nuvem e sensoriamento remoto

Segundo Manvi e Krishna Shyam (2014), a computação em nuvem pode ser definida como um local sobre uma infraestrutura de rede em que a tecnologia da informação e recursos computacionais, como *hardware*, sistemas operacionais, redes, armazenamento, bancos de dados e *softwares* aplicativos estão disponíveis instantaneamente, em demanda. Essa possibilita disponibilizar recursos em nuvem (*hardware e software*), que são entregues como serviços pela rede.

O avanço da pesquisa de interoperabilidade geoespacial estimulou a disseminação de recursos geoespaciais compartilhados via *web*. No entanto, a crescente disponibilidade, devido à geração de grandes volumes de dados, tornou-se um desafio (HAN et al., 2016; LI; WANG; BHATIA, 2016). As ciências geoespaciais enfrentam grandes desafios da tecnologia da informação (TI) no século XXI, como: intensidade dos dados, intensidade computacional, intensidade de acesso simultâneo e intensidade espaço-temporal (YANG et al., 2011).

Nos últimos anos, o processamento de dados distribuídos atingiu muitas áreas da ciência da computação, SIGs e SR. Um grande desafio é que com o aumento contínuo de dados, os algoritmos e o gerenciamento de dados existentes precisarão ser transferidos para

uma nova arquitetura (GIACHETTA, 2015). Abordagens baseadas em *desktop* têm sido complementadas com estruturas de armazenamento em nuvem e processamento de grande volume de dados (CRUZ; SILVA; NEVES, 2016).

O custo computacional do SR é frequentemente caro, os métodos tradicionais não satisfazem o requisito de tempo em monitoramentos dinâmicos. A computação em nuvem fornece um serviço eficiente para gerenciamento de dados e execução para o sensoriamento remoto. Esta poderá integrar serviços de processamento e arquitetura, fornecendo aos usuários serviços rápidos e a possibilidade de gerenciamento e análise de grandes quantidades de dados de forma distribuída (WANG et al., 2013).

A computação em nuvem emerge como fronteira popular na tecnologia da informação e nas comunidades geoespaciais (YANG; XU; NEBERT, 2013). Surge como um novo paradigma para fornecer a computação como um serviço de utilidade, com cinco características vantajosas: a) poder de computação rápido e elástico; b) agrupar o poder de computação para melhor utilizar e compartilhar recursos; c) acesso em banda larga para comunicação rápida; d) acesso sob demanda para computação como serviços de utilidade pública; e) pagar recursos conforme uso, sem um custo inicial significativo, como recursos computacionais tradicionais físicos (YANG et al., 2017).

O paradigma da computação em nuvem facilitou o processamento de dados de SR. Ao contrário dos métodos convencionais de processamento utilizando um servidor ou *software* autônomo, o processamento de dados de SR baseado em nuvem, pode ser caracterizado pela disponibilidade de recursos de computação ilimitados (WANG et al., 2018). Sendo assim, a nuvem oferece dois benefícios em relação aos SIGs tradicionais. 1) Computação de alto desempenho, em que fornece recursos praticamente ilimitados em termos de capacidade de processamento e memória. Infraestruturas de nuvem são escaláveis e elásticas, o que significa que novos recursos podem ser adquiridos sob demanda. Dados geoespaciais podem ser processados de forma mais rápida e prática. 2) Serviços distribuídos, em que uma solução *Software* como Serviço (SaaS) oferece serviços que podem ser usados para acessar, processar, visualizar e compartilhar dados, metadados e modelos de vários domínios, para várias finalidades. O acesso a informações geoespaciais intertemáticas e interligadas ajuda os especialistas em SIG no planejamento e tomada de decisão (KRÄMER; SENNER, 2015).


Apesar de as vantagens da computação em nuvem, alguns obstáculos permanecem, dificultando a adoção da nuvem em aplicações de SR. Para atender às necessidades futuras de exploração e aplicações de SR em larga escala, a distribuição de dados e as escalas de computação devem continuar expandindo e impulsionando a evolução de plataformas de processamento. O armazenamento, gerenciamento e complexidade de dados será desafiador, sendo assim, para fornecer um serviço on-line abrangente e conveniente para usuários, uma interface orientada a serviços é de grande importância (WANG et al., 2018).

### 3.3 Processamento digital de imagens (PDI)

Uma imagem pode ser definida como uma função  $f(x, y)$ , sendo essa função bidimensional.  $X$  e  $y$  são tratados como coordenadas espaciais e a amplitude de  $f$  em qualquer par de coordenadas  $x$  e  $y$  é chamada de intensidade ou nível de cinza da imagem, nesse determinado ponto  $x$  e  $y$ . Este ponto também pode ser caracterizado como *pixel* (GONZALEZ; WOODS, 2010).

Uma imagem digital obtida por SR é uma representação matricial dos valores refletidos ou emitidos pela superfície terrestre, na qual cada elemento de resolução (*pixel*) representa uma intensidade de energia em um nível de cinza. Quanto maior o nível de cinza, maior é a energia. Uma imagem do satélite *Landsat* (até a versão 7), por exemplo, é representada em 256 níveis de cinza (de 0 a 255), ou seja, em 8 bits ( $2^8$ ) (FLORENZANO, 2011).

O processamento digital de imagens consiste em técnicas para capturar, representar e transformar imagens, utilizando um computador e permitindo extrair e identificar informações das imagens, alterando a qualidade visual de certos aspectos, facilitando a percepção humana e a interpretação automática por meio de máquinas. Um sistema de processamento digital de imagens é constituído por etapas (Figura 6), em que é possível chegar a um resultado ou conclusão a partir de um domínio do problema (aquisição da imagem) (PEDRINI; SCHWARTZ, 2008).



**Figura 6** Etapas de um sistema de processamento digital de imagens.

**Fonte:** Persechino e Albuquerque (2015).

A etapa de aquisição da imagem e digitalização é realizada por meio de um dispositivo ou sensor, no qual ela é convertida para uma representação adequada. A etapa de pré-processamento é utilizada para melhorar a qualidade da imagem com técnicas para atenuação de ruído, correção de contraste ou brilho e suavização de determinadas propriedades da imagem. A etapa de segmentação realiza a extração e identificação de áreas de interesse. As etapas de pós-processamento e extração de atributos são utilizadas para armazenar e manipular objetos de interesse extraídos. E a etapa de classificação e reconhecimento envolve a interpretação dos componentes de uma imagem (PEDRINI; SCHWARTZ, 2008).

Para compreender os tipos de transformação aplicados aos dados de SR, essas técnicas podem ser agrupadas em três conjuntos: pré-processamento, realce e classificação. Do ponto de vista do processamento dos dados digitais, as características importantes nas imagens de SR são: resolução espectral, resolução espacial e resolução radiométrica. O número de bits utilizado para representar a informação vai ter impacto na qualidade radiométrica do objeto (FLORENZANO, 2011).

É fundamental ter conhecimento a respeito das características das imagens para utilizar adequadamente os sistemas de processamento e análise de dados digitais. O tamanho da imagem, o número de bandas espectrais, a resolução espacial e a resolução radiométrica definem o volume de dados a serem processados (MORAES NOVO, 2010).

O pré-processamento tem a finalidade de calibrar a radiometria da imagem, atenuar os efeitos da atmosfera, remover ruídos e corrigir distorções geométricas por meio de georreferenciamento. As coordenadas da imagem (linha e coluna) são relacionadas com as coordenadas geográficas (latitude e longitude) de um mapa. Cada *pixel* da imagem é ajustado com um ponto na superfície representativa da Terra. Técnicas de pré-processamento também são utilizadas para reduzir o efeito da topografia nas imagens (PEDRINI; SCHWARTZ, 2008).

Técnicas de realce são utilizadas para melhorar a qualidade visual das imagens e facilitar sua interpretação. As técnicas mais utilizadas são: ampliação linear de contraste, eficiente para destacar objetos e feições; operações aritméticas, para realçar as similaridades e diferenças espectrais; transformação por componentes principais, em que é possível reduzir a dimensionalidade dos dados ou integrar dados de diferentes sensores; transformação por IHS, em que a partir de uma composição RGB, é possível desagregar as informações espectrais nas componentes matiz (*hue*), saturação (*saturation*) e a intensidade (*intensity*); filtragem espacial, com passa-baixas para atenuar as componentes de alta frequência da imagem e passa-altas para realçar as componentes de alta frequência; geração de composições coloridas; integração de dados, gerando imagens coloridas (FLORENZANO, 2011).

A segmentação é um passo anterior a um algoritmo de classificação. Permite dividir a imagem em regiões espectralmente homogêneas. Podem ser definidas amostras (áreas de treinamento) para algoritmos de classificação. Na segmentação deve-se aplicar dois limites: de similaridade e área. Técnicas de classificação de imagens digitais visam à identificação de objetos, em função de critérios de decisão, agrupando em classes os objetos que apresentarem similaridade em suas respostas espectrais, tendo como resultado um mapa temático, em que cada *pixel* ou grupo de *pixels* é classificado em uma classe. O pós processamento tem como objetivo corrigir erros apresentados pela classificação (PEDRINI; SCHWARTZ, 2008).

O uso de dados espectrais transformados (também pode ser dito realçado) é, muitas vezes, mais conveniente do que os originais. Dentre os métodos de transformação em imagens de SR, destacam-se: rotação espectral; restauração; IVs e o modelo linear de mistura espectral. O objetivo da rotação espectral é realizar transformações lineares nas imagens, combinando informações espectrais de várias bandas, para gerar novas imagens com informações espectrais mais contrastadas do que as bandas originais. Os IVs (como o NDVI) se baseiam em uma assinatura espectral característica de uma vegetação sadia e verde, com

contraste entre a região do visível, especificamente o vermelho e a do infravermelho próximo. O modelo linear de mistura espectral é utilizado para decompor uma imagem em três novos componentes: vegetação, solo e sombra (MOREIRA, 2011).

### 3.4 Ferramentas (bibliotecas) para manipulação de dados espaciais

Avanços no desenvolvimento de *softwares* de código aberto, padrões abertos e interfaces abertas mostram potencial para superar esses problemas. A padronização de interfaces e formatos sugerida pelo *Open Geospatial Consortium* (OGC) pode garantir a interoperabilidade dos sistemas de informações geográficas (SIG) (JEPPESEN et al., 2018).

Bibliotecas são coleções de classes e outros módulos que podem ser manipulados por linguagens de programação, vinculados a *softwares* existentes e criar módulos de processamento. Ao manipular bibliotecas, que seguem a padronização OGC, no contexto de processamento de serviços na *web* (WPS), é possível construir um *software* cliente inteiro a partir do zero, vincular o servidor WPS ao *software* do servidor da *web* e desenvolver processos (EVANGELIDIS et al., 2014).

Bibliotecas contribuem diretamente para a implementação de WPS, por meio de componentes e *plugins* desenvolvidos justamente para esse propósito. Os componentes e *plugins* também podem suportar diferentes plataformas e serem manipulados e estendidos por uma ampla gama de linguagens de programação (EVANGELIDIS et al., 2014). Na Tabela 1 estão alguns exemplos de bibliotecas *open source*, que seguem o padrão OGC.

**Tabela 1** Bibliotecas para auxílio de implementação de *softwares* geoespaciais

Nome	Projeto	Linguagens	Suporte
	URL		Plataformas
GDAL/OGR	OGC <a href="http://www.gdal.org">http://www.gdal.org</a>	C++	Windows, Linux, Mac OS X
GeoTools	OpenGeo, Geosolutions, Refrations Research, LISAsoft <a href="http://www.geotools.org/">http://www.geotools.org/</a>	Java	Qualquer plataforma
HSLayers	HS-RS <a href="http://hslayers.org/">http://hslayers.org/</a>	Javascript	Qualquer plataforma
OpenLayers	OpenGeo <a href="http://opengeo.org/technology/openlayers/">http://opengeo.org/technology/openlayers/</a>	Javascript	Qualquer plataforma

**Fonte:** Adaptado de (Evangelidis et al., 2014).

Selcuk-Kestel, Duzgun, Lutfi (2012) desenvolveram um *software desktop* baseado em SIG para a avaliação de terremotos, utilizando a biblioteca GeoTools. Dawidowicz et al., (2020) também utilizaram a biblioteca GeoTools no desenvolvimento de um sistema de informação agrícola para atender às necessidades de uma política agrícola sustentável, apoiando a tomada de decisão em AP e ameaças à colheita, para a Polônia. Sun, Di e

Gaigalas (2019) propuseram um *framework* inovador chamado SUIS para simplificar o uso de *web services* geoespaciais, utilizando a biblioteca GeoTools e conceitos de *web service*.

Song et al. (2016) trabalharam com a biblioteca GeoTools em vários cenários, incluindo a aplicação estatística em imagens *raster*, uma importante ferramenta para suporte a uma variedade de aplicações SIG. Uma série de experimentos foram conduzidos para avaliar o desempenho dos algoritmos e os resultados mostraram que o GeoTools fornece ótimas funcionalidades para aplicações estatísticas em formato *raster* e seu uso em estruturas de análise espacial e representação de dados espaço- temporais.

## 4 MATERIAL E MÉTODOS

### 4.1 Softwares e tecnologias utilizadas


Para as representações gráficas da análise e documentação dos requisitos de *software* foi utilizada a Linguagem de Modelagem Unificada (UML), que tem por objetivo auxiliar o desenvolvedor na fase de análise e implementação do *software* (GUEDES, 2018). Os diagramas foram modelados pela plataforma *online Gliffy*, gratuita para os diagramas utilizados neste trabalho.

Utilizou-se para o desenvolvimento do *back-end* (API) a linguagem de programação orientada a objetos Java, versão 8 (1.8.0\_221), com a *Integrated Development Environment* (IDE) *Spring Tools Suite* versão 3 (3.9.9). Para o desenvolvimento do *front-end* (sistema *web*) utilizaram-se as linguagens *typescript* e *Cascading Style Sheets* (CSS), baseadas no *framework* Angular, com a IDE *Visual Studio Code*, versão 1.52.1.

Também foi utilizada a API de mapas *Agro API* (<https://openweathermap.org/api>). A *Agro API* mantém licença aberta *Creative Commons BY-AS 4.0*, sendo possível compartilhar e adaptar seu conteúdo.

### 4.2 Área de estudo

A área do experimento (Figura 7) fica localizada no município de Céu Azul, região oeste do estado do Paraná, com área de 16 ha<sup>-1</sup> e localização centralizada nas coordenadas 25°06'32" S e 53°49'55" O.




**Figura 7** Área de estudo, em Céu Azul, Paraná.

### 4.3 Plataforma AgDataBox (ADB)

#### 4.3.1 Visão geral

A plataforma *web* AgDataBox (ADB, Figura 8) disponibiliza ferramentas computacionais gratuitas para produtores rurais, pesquisadores e prestadores de serviços, abordando principalmente as práticas de AP. Nessa plataforma, há integração de dados, *softwares*, procedimentos e metodologias, com o intuito de viabilizar o crescimento da gestão agrícola no país por meio de tecnologias livres. Ela está estruturada em aplicações subdivididas em módulos. O ADB possui uma *Application Programming Interface* (API), a aplicação ADB-Data-API, para armazenamento de dados, acessível por meio de *Hypertext Transfer Protocol* (HTTP). A ADB-Data-API permite a interoperabilidade de diversas aplicações, nas quais são centralizados os dados. Algumas aplicações em fase de teste ou em desenvolvimento que consomem recursos da ADB-Data-API: (i) ADB-Mobile (SCHENATTO et al., 2017), (ii) ADB- Map (BORGES et al., 2020; MICHELON et al., 2019), (iii) ADB-Admin; 4-ADB-IoT.




**Figura 8** Arquitetura da plataforma AgDataBox (ADB).

A ADB-Data-API (disponível em nuvem) é responsável pelo armazenamento dos dados e pela disponibilidade das rotinas (microsserviços) de todos os módulos da plataforma. A aplicação ADB-mobile é responsável por realizar coletas de dados georreferenciados e informações pertinentes às ações desenvolvidas pela plataforma. A aplicação ADB-Admin é responsável pela administração dos dados armazenados em nuvem. A aplicação ADB-Map trabalha com a geração de mapas temáticos a partir do conjunto de dados inseridos na API. A aplicação ADB-IoT fornece dados por meio de sensores para integração.

Este trabalho apresenta o desenvolvimento da aplicação computacional de gerenciamento de dados de sensoriamento remoto (ADB-RS) para a plataforma ADB.

A integração dos serviços é realizada através de *web services* do tipo REST, via microsserviços pelo protocolo HTTP e arquivos no padrão JSON. Observa-se na Figura 9 a integração entre a plataforma e diversos serviços previstos, como: imagens de satélite, mapas, sensores, dados climáticos e amostragem, dentre outros.




**Figura 9** Comunicação entre AgDataBox API e serviços.

Fonte: Adaptado de Bazzi *et al.* (2019).

#### 4.3.2 Aplicação AgDataBox - sensoriamento remoto (ADB-RS)

O ADB-RS é uma aplicação computacional híbrida (Figura 10), que pode ser acessado por meio de um computador pessoal ou *notebook*, *tablets*, *smartphones* e dispositivos embarcados. O acesso à plataforma será realizado por qualquer um destes dispositivos, de forma ubíqua, desde que possua condições de acesso à rede de *internet* e um *browser* com acesso à conexão HTTP para consumo dos microsserviços da plataforma.




**Figura 10** Estrutura da aplicação AgDataBox-RS que irá compor a plataforma AgDataBox.

A comunicação entre clientes e a aplicação ADB-RS ocorre pelo consumo dos microsserviços implementados na plataforma ADB. As funções fornecidas pela camada de aplicação (Aquisição, processamento e transformações) estão registradas no Catálogo de Serviços do módulo e estão disponíveis para os clientes e os demais módulos da plataforma ADB.

O Catálogo de Serviços traz a lista de microsserviços que serão disponibilizados pelo módulo. A comunicação entre módulos será realizada através de arquivos padronizados do tipo JSON/GeoJSON. Esse formato apresenta interoperabilidade com as bibliotecas que serão utilizadas no desenvolvimento do projeto. Os dados são persistidos (salvos) em um banco de dados com extensão espacial.

Observa-se na Figura 11, de forma detalhada, o funcionamento da aplicação ADB-RS.




**Figura 11** Funcionalidades da plataforma ADB-RS apresentadas de forma detalhada.

### Aquisição de dados

As imagens são adquiridas em formato *raster*, via comunicação HTTP REST com a plataforma *online* de mapas *Agro API*. Essa plataforma disponibiliza imagens dos satélites *Sentinel-2* e *Landsat-8* nos formatos PNG e Tif/GeoTif. Imagens *Sentinel-2* apresentam resolução espacial de 10 metros e *Landsat-8* de 30 metros.

É possível filtrar a busca de imagens por um período de interesse, trabalhar com bandas do visível (*RGB: Red, Green, Blue*) e índices de vegetação (IVs). Estão implementados os seguintes IVs: (i) *Normalized difference vegetation index* (NDVI); (ii) *Enhanced vegetation index* (EVI); (iii) *Enhanced vegetation index* (EVI 2); (iv) *Disease water stress index* (DSWI); (v) *Normalized difference water index* (NDWI); e (vi) *Nitrogen reflectance index* (NRI).

Para a apresentação das imagens de IVs, é possível utilizar 4 paletas de cores diferentes para apresentação (Figura 12).



**Figura 12** Paletas de cores para serem utilizadas na apresentação de imagens *raster* do tipo IVs.

**Nota:** O valor de cada *pixel* nas imagens tem uma variação de -1 até 1, conforme seus algoritmos.

Para a geração de gráfico por período, é possível filtrar os dados apresentados pelo percentual de nuvem e pelo satélite referente à imagem.

### Processamento

Após a aquisição da imagem, o próximo passo é o seu processamento. Para realizar a leitura e o processamentos das imagens *raster* em linguagem Java, utilizaram-se as classes *GridReader*, *GridCoverage*, *Raster* e *Process* da biblioteca *GeoTools*. Com o auxílio dessas classes é possível manipular *pixels* de uma imagem *raster*, tais como coordenadas geoespaciais e valores registrados em cada *pixel*. Também é possível separar as bandas do RGB e trabalhar com as bandas de forma individual.

### Transformações

Após a imagem ser lida e processada, o próximo passo é realizar a vetorização das imagens *raster* em arquivos do tipo WKT ou JSON/GeoJSON. Para essa tarefa utilizaram-se as classes *Process*, *Polygon Extraction*, *WKT* e *JSON* da biblioteca *GeoTools*.


### Exportar

Após as imagens serem processadas e transformadas no formato padronizado da plataforma ADB, elas estão aptas para serem inseridas na aplicação API da plataforma. Após as imagens serem persistidas (salvas), é possível que outros módulos da plataforma acessem e manipulem os dados.

A funcionalidade Vetorizar, implementada na aplicação, acessa um microserviço do *back-end* do módulo, envia as imagens adicionadas e como resposta, recebe as mesmas, transformadas em JSON. Com as imagens padronizadas em JSON, o *front-end* acessa o

microserviço da plataforma ADB e insere os dados vetorizados para que os mesmos possam ser acessados e utilizados pelo módulo ADB-Map.

O diagrama de atividades (Figura 13) tem o intuito de apresentar o funcionamento do módulo ADB-RS, dando ênfase nas etapas de seu funcionamento.



**Figura 13** Diagrama de atividades da aplicação ADB-RS.

A comunicação entre *back-end* e API de imagens de satélite é realizado através de uma requisição no formato HTTP, pela qual se obtém um resultado no padrão JSON. Além das imagens *raster*, a Agro API retorna outros parâmetros (Tabela 2).


**Tabela 2** Parâmetros retornados no formato JSON em um acesso HTTP

Parâmetro	Descrição
dt	Data da imagem (no formato <i>Unix timestamp</i> )
type	Tipo do satélite ( <i>Sentinel-2</i> ou <i>Landsat-8</i> )
dc	Porcentagem de cobertura da área.
cl	Porcentagem de nuvens presente na imagem
elevation	Altura acima ou abaixo do ponto de referência.
azimuth	Medição angular com base no sistema de coordenadas da imagem.

É possível visualizar em qual camada cada evento ocorre e qual é a ordem cronológica/dependência das funções. A funcionalidade Poligonizar (Figura 13) descrita na ação Converter para JSON é o mesmo que a vetorização apresentada na camada Transformações (Figura 11).


### Seleção de variáveis, delineamento e avaliação de zonas de manejo

Foram utilizados dados amostrais (Figura 14) de textura de solo (areia, silte e argila), altitude e resistência de solo à penetração (0-0.1m, 0-0.2m, 0.1-0.2m e 0.2-0.3m).



**Figura 14** Pontos de coleta dos dados amostrais.

Os dados de satélite utilizados foram vetorizados pelo módulo ADB-RS. O processo de delineamento de ZMs foi realizado no módulo ADB-Map (MICHELON et al., 2019). Observa-se na Figura 15 uma sequência de 8 passos utilizados para o delineamento de ZMs.



**Figura 15** Metodologia utilizada para o delineamento de zonas de manejo.

**Passo 1** - os dados amostrais passaram pelo processo de limpeza no módulo ADB-Clean, no qual se removeram valores duplicados, nulos e negativos, fora do intervalo da média  $\pm$  três DP, considerados *outliers*, e dos *inliers* identificados pelo Índice Local de Moran.

**Passo 2** - realizou-se a redução/transposição do conjunto de dados, para que os conjuntos tivessem a mesma dimensão. Para essa tarefa foi utilizada a função de média móvel, conforme Equação 5 (BORGES *et al.*, 2020).

$$Z = \frac{\sum_{i=1}^n (Z_i)}{n} \quad (5)$$

Em que

$Z_i$  = valor do Z em relação ao seu vizinho i;

n = número de elementos da amostra utilizados para normalização.

**Passo 3** – realizou-se a seleção de variáveis a serem utilizadas no delineamento das ZMs, utilizando-se o método da matriz de correlação espacial. Esse método foi utilizado com base nos ótimos resultados obtidos em Gavioli *et al.* (2016) e Schenatto *et al.* (2016). Para avaliar a correlação espacial entre as variáveis, foi utilizada a estatística de autocorrelação espacial bivariada de Moran (CZAPLEWSKI; REICH, 1993; DRIEMEIER *et al.*, 2016), que permite determinar quais atributos influenciam de forma positiva ou negativa e mostra se cada variável está espacialmente correlacionada. As variáveis foram selecionadas considerando-se a abordagem proposta por Bazzi *et al.* (2013), a partir das variáveis candidatas ao delineamento de ZMs são eliminadas as com dependência espacial não significativa, as sem correlação com a variável alvo e as redundantes.

**Passo 4** – os dados foram normalizados. Para os dados que não apresentam variação temporal, como areia, silte, argila e altitude, utilizou-se o método de amplitude (Equação 6). Como os dados de IV apresentam dependência temporal, foram normalizados pelo método da média (*Average*, Equação 7). O objetivo da normalização é manter o mesmo intervalo de dados, independentemente da variável de uso (GAVIOLI *et al.*, 2016; SCHENATTO *et al.*, 2017).

$$Z = \frac{x - \text{median}}{\max(x) - \min(x)} \quad (6)$$

Em que

X = valor do *pixel* a ser normalizado;

Z = resultado da normalização.

$$Z = \frac{x}{\bar{x}} \quad (7)$$

Em que

$\bar{x}$  = total de amostras;

Z = resultado da normalização.

**Passo 5** – as variáveis selecionadas foram interpoladas. Utilizando-se o método Inverso da Distância Ponderada (IDW) e as rotinas desenvolvidas por Betzek *et al.*, (2019), identificando o melhor expoente IDW, que atua como um estimador determinístico, considerando os pontos mais próximos do local a ser medido mais representativos do que os mais afastados, de acordo com as distâncias lineares das amostras.

**Passo 6 e 7** - as ZMs foram delineadas e retificadas utilizando-se as variáveis selecionadas e interpoladas. Foram delineadas ZMs com duas, três e quatro classes pelo método de agrupamento *fuzzy c-means* (BEZDEK, 1981; RUSPINI, 1969), utilizando o valor de peso sugerido de 1,3 (FRIDGEN *et al.*, 2004; ODEH; MCBRATNEY; CHITTLEBOROUGH, 1992) e um valor de erro definido como o mais baixo possível (0.0001). A retificação foi aplicada pelos filtros de mediana (BETZEK *et al.*, 2018), com cinco interações.

**Passo 8** – as ZMs foram avaliadas utilizando-se a análise de variância (ANOVA) (BETZEK *et al.*, 2019; SCHENATTO *et al.*, 2017) e os seguintes índices:

1) *Variance Reduction Index* – Índice de Redução da Variância (VR, Equação 8) (DOBERMANN *et al.*, 2003; XIANG *et al.*, 2007). Esse índice calcula o rendimento médio padronizado com a expectativa de que a soma das variâncias dos dados gerados a partir das ZMs seja menor que a variância total. Quanto maior o valor deste índice, melhor é o resultado.

$$VR = \left( 1 - \frac{\sum_{i=1}^c W_i * V_{MZi}}{V_{field}} \right) \quad (8)$$

Em que

$c$  = número de ZMs;

$W_i$  = proporção da área em cada ZM;

$V_{MZi}$  = variação dos dados de cada ZM;

$V_{field}$  = variação da amostra de dados para toda a área.

2) *Fuzziness Performance Index* - Índice de Desempenho Fuzziness (FPI, Equação 9) (FRIDGEN *et al.*, 2004). Esse índice permite determinar o grau de separação entre os *fuzzy c-groups* gerados a partir de um conjunto de dados. Quando os valores de FPI se aproximam de 0, classes distintas são indicadas com pequeno grau de compartilhamento entre os grupos gerados, enquanto os valores próximos a 1 não indicam classes distintas, com um elevado grau de compartilhamento entre os grupos gerados. Quanto menor é o valor desse índice, melhor é o resultado.

$$FPI = 1 - \frac{c}{(c-1)} \left[ 1 - \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^2 / n \right] \quad (9)$$

Em que

- $c$  = número de *clusters*;
- $n$  = número de observações;
- $u_{ij}$  = elemento da matriz *fuzzy*.

3) *Modified Partition Entropy Index* – Índice de Entropia de Partição Modificada (MPE, Equação 10) (BOYDELL; MCBRATNEY, 2002). Esse índice estima a quantidade de desorganização existente por um número específico de *clusters*. Valores próximos a 1 indicam que predomina a desorganização e valores próximos a 0 indicam uma melhor organização.

$$MPE = \frac{\sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij})/n}{\log c} \quad (10)$$

Em que

- $c$  = número de *clusters*;
- $n$  = número de observações;
- $u_{ij}$  = elementos da matriz *fuzzy*.

4) *Smoothness Index* – Índice de Suavidade (SI, Equação 11) (GAVIOLI et al., 2016). Esse índice calcula a frequência das mudanças de classe *pixel a pixel* no mapa temático, nas direções horizontal, vertical e diagonal. Para mapas com classes uniformes, o valor de SI tende a 100 e mapas com muitas mudanças entre as classes tendem a valores mais baixos.

$$SI = 100 - \left( \left( \frac{\sum_{i=1}^k NM_{Hi}}{4P_H} + \frac{\sum_{j=1}^k NM_{Vj}}{4P_V} + \frac{\sum_{i=1}^k NM_{Ddl}}{4P_{Dd}} + \frac{\sum_{m=1}^k NM_{Dem}}{4P_{De}} \right) * 100 \right) \quad (11)$$

Em que

- $NM_{Hi}$  = número de mudanças na linha  $i$  (horizontal);
- $NM_{Vj}$  = número de mudanças na coluna  $j$  (vertical);
- $NM_{Ddl}$  = número de mudanças na diagonal  $l$  (diagonal direita - DD);
- $NM_{Dem}$  = número de mudanças na diagonal  $m$  (diagonal esquerda - DE);
- $K$  = número máximo de *pixels* na linha, coluna ou diagonal;
- $PH$  = possibilidade de mudança nos *pixels* horizontalmente;
- $PV$  = possibilidade de mudança nos *pixels* verticalmente;
- $P_{Dd}$  = possibilidade de mudança na diagonal direita – DD;
- $P_{De}$  = possibilidade de mudança na diagonal esquerda – DE.

5) *Improved Cluster Validation Index* – Índice de Validação de *Cluster* Aprimorado (ICVI, Equação 12) (GAVIOLI et al., 2016). Esse índice é baseado no índice CVI, proposto por (SCHENATTO et al., 2016), e tem como propósito resolver um possível problema quando as estimativas para FPI, MPE e VR não indicam um resultado semelhante ao delineamento de

ZMs. Quanto maior o valor de VR e menores os valores de FPI e MPE, mais próximo o ICVI estará de 0 e, quanto menor for o ICVI, melhor será o método de agrupamento.

$$ICVI_i = \frac{1}{3} * \left( \frac{FPI_i}{Max\{FPI\}} + \frac{MPE_i}{Max(MPE)} + \left( 1 - \frac{VR_i}{Max\{VR\}} \right) \right) \quad (12)$$

Em que

$FPI_i$  = valor do FPI para o i-ésimo método de seleção de variável;

$MPE_i$  = valor do MPE para o i-ésimo método de seleção de variável;

$VR_i$  = valor do VR para o i-ésimo método de seleção de variável;

$MAX\{ÍndiceX\}$  = representa o valor máximo do índice X entre os n métodos de seleção de variáveis.

6) ANOVA: Os valores foram comparados entre as ZMs utilizando o teste de Tukey para identificar se as sub-regiões apresentavam diferenças significativas.

7) Coeficiente *kappa* (K) (COHEN, 1960). Compara o nível de concordância entre dois delineamentos de ZMs. Landis e Koch (1977) propuseram a classificação  $0 < K < 0,4$  como fraca concordância,  $0,4 < K < 0,6$  como concordância moderada,  $0,6 < K < 0,8$  como concordância forte, e  $0,8 < K < 1,0$  como concordância muito forte.

8) *Fragmentation Index* – Índice de Fragmentação (FI%, Equação 13). Esse índice leva em consideração quão maior é o número de ZMs, em relação ao número de classes.

$$FI\% = 100 \frac{NMZ-NC}{NC} \quad (13)$$

Em que

NZM = número de ZMs;


NC = número de classes.

9) *Global Quality Index* – Índice Global de Qualidade (GQI, Equação (14)). Esse índice busca o melhor número de classes em um delineamento de ZMs, com base nos valores de ICVI,  $Si_r$  e  $FI_r$ .

$$GQI_i = \frac{ICVI_i * (100 + FI_r)}{SI_r} \quad (14)$$

## 5 RESULTADOS E DISCUSSÃO

A interface de busca de imagens para talhões do ADB-RS é apresentada na Figura 16. O intervalo definido para este estudo foi de outubro/2018 a abril/2019, período no qual foi cultivado milho, safra 2018/2019. No quadro Histórico é apresentado um gráfico com os valores de NDVI, com filtragem por satélite, com imagens do *Sentinel-2* e com porcentagem de nuvens inferior a 5%. A linha verde representa a média dos valores para o período e a linha azul representa o valor máximo registrado para o período.



**Figura 16** Interface de busca de imagens para talhões do ADB-SR.

**Notas:** A imagem *raster* selecionada é referente a data de 15 de janeiro de 2019.





O histórico apresenta um gráfico com valores de NDVI de 27/10/2018 até 10/04/2019.

O mês de outubro apresentou apenas uma imagem no gráfico (27/10/2018), pois as demais imagens recuperadas pelo satélite *Sentinel-2* apresentaram presença de nuvens superior ao filtro aplicado. O quadro Estatísticas apresenta o número de *pixels*, os valores de máximo, mínimo, média, mediana, desvio padrão e o 1º e 3º quartil da imagem selecionada. A listagem Imagens disponíveis apresenta todas as imagens recuperadas pelo filtro de período aplicado, apresentando o satélite, a data da imagem, a porcentagem de cobertura da área e a porcentagem de nuvens. Para o caso da imagem selecionada (15/01/2019,

*Sentinel-2*) o valor máximo para o índice NDVI foi de 0,7344, houve 100% de cobertura da área e teve 0,1% de nuvens. É possível realizar o *download* da imagem no formato PNG ou TiF. Observa-se nos Apêndices A, B e C as demais interfaces e funcionalidades do módulo computacional desenvolvido, de modo detalhado.

A área Imagens selecionadas (Figura 15) armazena as imagens que o usuário tem interesse em sua vetorização (gerar arquivo vetorial de dados), no formato JSON, podendo realizar a exportação deste arquivo para a plataforma ADB por meio do botão 'Vetorizar', localizado abaixo de Imagens disponíveis.

A Figura 17 apresenta um comparativo dos índices NDVI, EVI e EVI2 em suas fases de desenvolvimento do cultivo de milho, na área de estudo. Os valores de IVs são apresentados com base na paleta 1 (Figura 12). Foram selecionadas imagens nas quais a condição meteorológica favorecesse a aplicação dos IVs, ou seja, imagens com ausência de nuvens com nível inferior a 5%.

Data (Sat.)	NDVI	EVI	EVI 2	Nuvens (%)
16/11/2018 (sentinel-2)				0,14
11/12/2018 (sentinel-2)				0,09
16/12/2018 (sentinel-2)				0,42
15/01/2019 (sentinel-2)				0,1
25/01/2019 (sentinel-2)				0,08
08/02/2019 (landsat8)				0,06
01/03/2019 (sentinel-2)				1,24

**Figura 17** Comparativo de IVs do cultivo de milho da safra 2018/2019.


**Nota:** Cores mais escuras correspondem a um valor de IV mais alto.

A imagem do dia 16/12/2018 apresentou valor máximo de NDVI de 0,62, mínimo de 0,19 e mediana de 0,32. Valor máximo de EVI de 0,56, mínimo de 0,12 e mediana de 0,25. Valor máximo de EVI2 de 0,41, mínimo de 0,1 e mediana de 0,19. A imagem do dia 11 de dezembro de 2018, apresentou valor máximo de NDVI de 0,74, mínimo de 0,53 e mediana de 0,70. Valor máximo de EVI de 0,81, mínimo de 0,47 e mediana de 0,72. Valor máximo de EVI2 de 0,55, mínimo de 0,34 e mediana de 0,50.

Durante os meses de dezembro e janeiro, o cultivo esteve em seu pico vegetativo, apresentando redução do NDVI em março, associado à senescência natural da cultura (SEO et al., 2019; SON et al, 2014). Os maiores valores registrados (pico vegetativo) ocorreram no dia 16/12/2018, com valor máximo de NDVI de 0,80, mínimo de 0,42 e mediana de 0,75. Valor máximo de EVI de 0,82, mínimo de 0,32 e mediana de 0,72. Valor máximo de EVI2 de 0,57, mínimo de 0,25 e mediana de 0,51.

Para apresentar a fenologia da cultura, conforme Son et al. (2014), foi necessário utilizar a imagem do dia 8 de fevereiro de 2019, obtida do satélite *Landsat-8*, visto que todas as imagens do *Sentinel-2* desse período estavam apresentando alta concentração de nuvens. Essa imagem apresentou valor máximo de NDVI de 0,72, mínimo de 0,45 e mediana de 0,68. Valor EVI máximo de 0,67, mínimo de 0,33 e mediana de 0,60. Valor máximo de EVI2 de 0,47, mínimo de 0,25 e mediana de 0,42.

Observam-se na Tabela 3 os valores estatísticos descritivos das imagens (IVs) apresentados na Figura 17. Pode-se observar, com auxílio do gráfico da Figura 18, que a média dos valores de NDVI, EVI e EVI-2, para o período analisado, apresentaram distribuição normal de probabilidade e sua fenologia apresentou o mesmo comportamento observado por Son et al. (2014).




**Figura 18** Valores médios dos índices NDVI, EVI e EVI-2 para todo o período fenológico da Safra 2018-2019.

**Tabela 3** Valores estatísticos de IVs para imagens no intervalo dos meses de novembro/2018, dezembro/2018, janeiro/2019, fevereiro/2019 e março/2019

	NDVI	EVI	EVI-2	NDVI	EVI	EVI-2	NDVI	EVI	EVI-2
	<b>16/11/2018</b>			<b>11/12/2018</b>			<b>16/12/2018</b>		
<b>DP</b>	0,02	0,02	0,01	0,02	0,04	0,02	0,05	0,07	0,04
<b>1º Q.</b>	0,30	0,23	0,18	0,69	0,71	0,49	0,75	0,72	0,51
<b>Min</b>	0,19	0,12	0,10	0,53	0,47	0,34	0,42	0,32	0,25
<b>Max</b>	0,62	0,56	0,41	0,74	0,81	0,55	0,79	0,82	0,57
<b>Média</b>	0,31	0,24	0,19	0,70	0,73	0,51	0,76	0,74	0,53
<b>3º Q.</b>	0,33	0,26	0,20	0,71	0,75	0,52	0,77	0,76	0,54
<b>Mediana</b>	0,32	0,25	0,19	0,70	0,72	0,50	0,75	0,72	0,51
<b>Pixels</b>	2002	2002	2002	2002	2002	2002	2002	2002	2002
	<b>15/01/2019</b>			<b>25/01/2019</b>			<b>08/02/2019</b>		
<b>DP</b>	0,01	0,02	0,01	0,02	0,03	0,01	0,02	0,04	0,03
<b>1º Q.</b>	0,70	0,66	0,45	0,70	0,64	0,44	0,67	0,58	0,41
<b>Min</b>	0,53	0,44	0,32	0,54	0,44	0,32	0,45	0,33	0,25
<b>Max</b>	0,73	0,72	0,49	0,73	0,71	0,49	0,72	0,67	0,47
<b>Média</b>	0,70	0,67	0,46	0,71	0,66	0,45	0,69	0,61	0,43
<b>3º Q.</b>	0,71	0,68	0,47	0,71	0,67	0,46	0,70	0,63	0,44
<b>Mediana</b>	0,70	0,66	0,45	0,70	0,65	0,45	0,68	0,60	0,42
<b>Pixels</b>	2002	2002	2002	2002	2002	2002	500	500	500
	<b>01/03/2019</b>								
<b>DP</b>	0,02	0,02	0,01						
<b>1º Q.</b>	0,28	0,15	0,11						
<b>Min</b>	0,23	0,11	0,08						
<b>Max</b>	0,49	0,33	0,25						
<b>Média</b>	0,30	0,16	0,12						
<b>3º Q.</b>	0,31	0,18	0,13						
<b>Mediana</b>	0,30	0,17	0,12						
<b>Pixels</b>	2002	2002	2002						


**Notas:** DP = Desvio padrão; 1º Q. = 1º quartil; Min = Mínimo; Max = Máximo; 3º Q. = 3º quartil.

Realizada a análise estatística das imagens de interesse, seguindo Son et al. (2014), foram selecionadas as imagens com valores de NDVI, EVI e EVI-2 próximos a seu pico vegetativo, com base no gráfico exibido na Figura 18 e nos valores analisados na Tabela 3. As imagens selecionadas (11/12/2018, 16/12/2018, 15/01/2019 e 25/01/2019) foram transformadas em vetor (Figura 19) e inseridas na aplicação ADB-Map.



**Figura 19** Vetorização de imagens do formato *raster* para o padrão JSON.

Foram inseridos 12 vetores no ADB-Map e gerado um vetor de médias para NDVI (NDVI\_NORMAL\_MÉDIA – NDVI\_NM), EVI (EVI\_NORMAL\_MÉDIA – EVI\_NM) e EVI2 (EVI2\_NORMAL\_MÉDIA – EVI-2\_NM), com base nas quatro imagens inseridas para cada índice, utilizando a funcionalidade ‘álgebra de *grids*’ do ADB-Map (Figura 20).



**Figura 20** Vetor de NDVI, EVI e EVI2 de médias normalizado.

Além dos vetores de médias para os IVS, foram inseridos vetores com valores de altitude, areia, silte, argila, produtividade (toneladas / ha) e resistência do solo à penetração (RSP) 0-0,1 m, RSP 0-0,2 m, RSP 0.1-0,2 m e RSP 0,2-0,3 m. Todos os vetores passaram pelo processo de limpeza dos dados (remoção de *inliers* e *outliers*). A normalização dos dados foi realizada conforme Schenatto et al. (2017). Na Tabela 4 é apresentada a estatística descritiva realizada para os elementos envolvidos no processo.

**Tabela 4** Resumo estatístico das variáveis

Variáveis	Média	Mediana	Mínimo	Máximo	Variância	DP	CV
NDVI_NM	0,72	0,72	0,69	0,73	0	0,01	1,63
EVI_NM	0,70	0,70	0,67	0,72	0	0,01	2,07
EVI-2_NM	0,49	0,49	0,46	0,52	0	0,01	2,08
Produtividade (t ha <sup>-1</sup> )	11,38	11,58	6,55	16,07	4,80	2,19	19,26
Altitude	663,7	662,9	656,3	671,8	16,134	4,017	0,605
Areia	19,22	19,25	18,25	20,25	0,235	0,485	2,52
Argila	61,51	51,5	59,62	63,12	0,944	0,971	1,579
Silte	19,26	19,12	18,12	20,5	0,382	0,618	3,208
RSP 0-0.1 m (MPa)	2,23	2,21	1,58	3,32	153,21	391,42	17,49
RSP 0-0.2 m (MPa)	2,25	2,25	1,73	2,82	63,96	252,91	11,22
RSP 0.1-0.2 m (MPa)	2,26	2,24	1,68	2,72	50,74	225,26	9,95
RSP 0.2-0.3 m (MPa)	1,91	1,89	1,33	2,29	51,72	227,43	11,85

**Notas:**

NDVI\_NM – Vetor de médias para as imagens NDVI dos dias 11/12/2018, 16/12/2018, 15/01/2019 e 25/01/2019;

EVI\_NM – Vetor de médias para imagens EVI dos dias 11/12/2018, 16/12/2018, 15/01/2019 e 25/01/2019;

EVI-2\_NM – Vetor de médias para imagens EVI2 dos dias 11/12/2018, 16/12/2018, 15/01/2019 e 25/01/2019;

DP – Desvio padrão; CV – Coeficiente de variação; RSP – Resistência do solo à penetração; MPa – megapascal.

O ADB-Map fornece uma funcionalidade pela qual é possível indicar qual é a variável alvo que se deseja para delinear as ZMs. Neste estudo foi escolhida a produtividade como variável alvo. Já com respeito à seleção das variáveis a serem utilizadas no processo de delineamento das ZMs foi utilizado o método Matriz de Correlação Espacial (BAZZI et al., 2013). Observa-se na Tabela 5 a análise de autocorrelação espacial entre as variáveis, extraída da aplicação ADB-Map, tendo as variáveis Altitude, EVI-2\_NM, EVI\_NM, NDVI\_NM e RSP 0.2-0.3 m. Na diagonal principal tem-se o teste de autocorrelação e nas células restantes o teste de correlação cruzada.

**Tabela 5** Matriz de correlação espacial, apresentando os valores de autocorrelação espacial e correlação espacial cruzada

Altitude	<b>0,00</b>											
Areia	0,64*	0,73*										
Argila	0,25*	0,85*	0,84*									
Silte	0,12*	0,99*	0,57*	0,29*								
RSP 0-0,1	<b>0,01</b>	0,16*	0,24*	0,47*	0,49*							
RSP 0-0,2	0,16*	0,11*	0,24*	0,65*	0,74*	0,85*						
RSP 0,1-0,2	0,97*	0,06*	0,28*	0,90*	0,99*	0,97*	0,91*					
RSP 0,2-0,3	0,59*	<b>0,02</b>	0,18*	0,97*	<b>0,04</b>	<b>0,04</b>	0,14*	<b>0,02</b>				
NDVI_NM	0,77*	<b>0,02</b>	0,06*	0,34*	<b>0,03</b>	<b>0,02</b>	<b>0,05</b>	<b>0,00</b>	<b>0,00</b>			
EVI_NM	0,41*	<b>0,01</b>	0,07*	0,61*	<b>0,00</b>	<b>0,00</b>	<b>0,00</b>	<b>0,00</b>	<b>0,00</b>	<b>0,00</b>		
EVI-2_NM	0,50*	<b>0,01</b>	0,12*	0,90*	<b>0,00</b>							
Produtividade	<b>0,01</b>	0,75*	0,10*	<b>0,01</b>	0,67*	0,84*	0,42*	0,51*	<b>0,03</b>	<b>0,01</b>	<b>0,01</b>	0,93*
	Altitude	Areia	Argila	Silte	RSP 0-0,1	RSP 0-0,2	RSP 0,1-0,2	RSP 0,2-0,3	NDVI_NM	EVI_NM	EVI-2_NM	Produtividade

**Notas:** RSP – resistência do solo à penetração; NDVI – índice de vegetação por diferença normalizada; EVI – índice de vegetação melhorado; \* nível de significância de 5%.


A partir da matriz de correlação especial, o ADB-Map executa o processo de seleção de variáveis em três passos (Tabela 6), resultando na escolha das variáveis altitude e EVI-2.

**Tabela 6** Processo de seleção de variáveis a serem utilizadas no delineamento de zonas de manejo

<b>Passo 1 – Seleção das variáveis autocorrelacionadas</b>		<b>Significância (5%)</b>
<b>Variável</b>	<b>Estatística</b>	<b>p-valor</b>
Altitude	0,1426	0,0000
RSP 0.2-0.3	0,1005	0,0210
NDVI	0,1174	0,0090
EVI	0,1833	0,0000
EVI-2	0,1923	0,0010
<b>Passo 2 – Seleção das variáveis correlacionadas com a variável alvo: produtividade</b>		<b>Significância (5%)</b>
NDVI	-0,050	0,0310
EVI	-0,0571	0,0140
EVI-2	-0,0581	0,0160
Altitude	0,0741	0,0060
<b>Passo 3 – Variáveis selecionadas após retirada das variáveis redundantes</b>		<b>Significância (5%)</b>
EVI-2	-0,0581	0,0160
Altitude	0,0741	0,0060


**Notas:** RSP – resistência do solo à penetração; NDVI – índice de vegetação por diferença normalizada; EVI – índice de vegetação melhorado.

As variáveis selecionadas (altitude e EVI-2) e a variável alvo (produtividade) foram então interpoladas pelo método do Inverso da Distância Ponderada (IDW). O expoente utilizado no modelo IDW foi escolhido automaticamente pelo ADB-Map, conforme metodologia desenvolvida por Betzek et al. (2019). O valor de expoente selecionado EVI-2\_NM foi 1, para Produtividade foi 2,5 e para Altitude foi 1. Observa-se na Figura 21 os mapas interpolados, classificados com quatro classes definidas por intervalos iguais.



**Figura 21** Mapa de interpolação por IDW aplicado dos vetores **a)** EVI2\_NORMAL\_MÉDIO; **b)** Produtividade; **c)** Altitude.

Foram delineadas ZMs com duas, três e quatro classes (Figura 22) utilizando três conjuntos de variáveis de entrada: (i) EVI-2\_NM, (ii) Altitude e (iii) EVI-2\_NM+Altitude. O método de agrupamento utilizado foi *fuzzy c-means* (BEZDEK, 1981). As ZMs foram então retificadas conforme Betzek et al. (2018).



**Figura 22** Zonas de manejo originais e retificadas, com duas, três e quatro classes, utilizando três conjuntos de variáveis de entrada: (a) EVI-2. (b) Altitude. (c) EVI-2+Altitude.

**Nota:** Cores mais escuras correspondem a uma maior produtividade média.

Observa-se na Tabela 7 a avaliação da qualidade das ZMs delineadas, utilizando-se a variável produtividade normalizada como variável alvo para o Teste de Tukey e cálculo dos índices de desempenho.

**Tabela 7** Análise estatística de avaliação das ZMs geradas

Tukey's Test													
C1	C2	C3	C4	VR	FPI	MPE	ICVI	SI(%)	Sir(%)	IF	IFr	GQI	
<b>2 classes</b>													
EVI-2	0,97a	1,04b		4,8	0,11	0,14	0,71	97,6	98,2	150	0	0,72	
Altitude	0,90a	1,08b		18,2	0,11	0,13	0,60	97,3	97,6	50	0	0,61	
EVI-2+Alti	0,84a	1,05b		23,6	0,12	0,16	1,02	98,6	99,0	50	0	1,03	
<b>3 classes</b>													
EVI-2	0,73a	0,98b	1,13c	54,7	0,09	0,09	0,31	96,1	96,5	132	67	0,54	
Altitude	0,72a	1,03b	1,10b	56,9	0,08	0,08	0,27	96,0	96,2	67	67	0,47	
EVI-2+Alti	0,74a	0,99b	1,09b	36,1	0,09	0,10	0,43	97,3	97,5	32	0	0,44	
<b>4 classes</b>													
EVI-2	0,69a	1,00b	1,08b	1,11b	49,8	0,09	0,09	0,34	94,9	95,4	100	75	0,62
Altitude	0,72a	1,03b	1,04b	1,16b	60,1	0,11	1,10	0,32	93,6	94,2	75	25	0,42
EVI-2+Alti	0,66a	1,00b	1,03b	1,15b	49,0	0,12	0,12	0,44	95,3	96,0	75	25	0,57

**Notas:** As letras a, b, c e d representam os resultados do teste de intervalo de Tukey, em que letras iguais significam que as classes correspondentes possuem diferenças não significativas ao nível de 0,05%.

Zonas de manejo com todas as classes estatisticamente diferentes foram ressaltadas com cinza.

Todos os delineamentos apresentaram ótima porcentagem de suavização (SI e Sir), com valores próximos a 100% e ótimos valores de MPE e FPI, com valores próximos a 0, determinando um ótimo grau de separação e um baixo índice de desorganização entre as classes.

Considerando as ZMs de duas classes, a que apresentou maior redução na variabilidade dos dados foi a de EVI-2+Altitude, com um valor de VR de 23,6. Para as ZMs de três classes, a que apresentou maior redução de variabilidade dos dados foi a Altitude, com um valor de VR de 56,9. Para as ZMs de quatro classes, a que apresentou maior redução na variabilidade dos dados foi a Altitude, com um valor de VR de 60%.

O delineamento que apresentou maior fragmentação foi o EVI-2, com valores de IF de 150% para duas classes, 133% para três classes e 100% para quatro classes. Reforçando que o IF é um índice que mede a fragmentação da área analisada e quanto menor seu valor, menos fragmentada é a área. O delineamento de três classes para EVI-2 apresentou valor de ICVI de 0,31, sendo um ótimo valor ICVI dentre todos delineamento analisados.

Na Tabela 8 estão apresentadas as comparações de ZMs EVI-2 x Altitude, Altitude x EVI-2+Altitude e EVI-2 x EVI-2+Altitude para duas, três e quatro ZMs, para avaliar a concordância de delineamento.


**Tabela 8** Comparação de índices de concordância (Kappa) entre as ZMs

Classes	ZMs	Kappa	Exatidão global
2	EVI-2 x Altitude	-0,06 (FR)	0,47
	Altitude x EVI2-Altitude	-0,23 (FR)	0,37
	EVI-2 x EVI-2-Altitude	0,81 (MF)	0,90
3	EVI-2 x Altitude	0,39 (MO)	0,55
	Altitude x EVI2-Altitude	0,41 (MO)	0,56
	EVI-2 x EVI-2-Altitude	0,86 (MF)	0,92
4	EVI-2 x Altitude	0,48 (MO)	0,62
	Altitude x EVI2-Altitude	0,76 (FO)	0,82
	EVI-2 x EVI-2-Altitude	0,61 (FO)	0,71

**Notas:** FR – Fraca; MO – Moderada; FO – Forte; MF – Muito forte.

A concordância foi classificada como muito forte para EVI-2 x EVI-2-Altitude com duas e três classes e forte para quatro classes. EVI-2 x Altitude apresentaram concordância fraca para duas classes, e moderadas para três e quatro classes. Altitude x EVI-2-Altitude apresentaram concordância fraca com duas classes, moderada para três classes e forte para quatro classes. Os valores de exatidão global acompanharam os valores Kappa, menores que 0,5 para valores Kappa fracos, entre 0,50 e 0,70 para moderados, entre 0,70 e 0,90 para fortes e maior que 0,90 para muito fortes.

Observa-se na Figura 23a o gráfico de dispersão para as ZMs de duas, três e quatro classes e seus valores de redução da variância (VR). As ZMs de três classes para EVI-2 e Altitude apresentaram valor similar de VR. Já com quatro classes, o maior valor de VR foi de Altitude. Observa-se na Figura 23b o gráfico de dispersão para as ZMs de duas, três e quatro classes e seus valores de índices de qualidade global (GQI). Na Figura 23(c) visualiza-se o gráfico de dispersão para as ZMs de duas, três e quatro classes e seus valores de ICVI; é possível notar a mesma tendência em todas ZMs, com destaque para altitude, que apresentou os melhores valores, seguido de EVI-2.



**Figura 23** Valores de dispersão para Altitude, EVI-2 e EVI2 e Altitude. **a)** VR para 2, 3 e 4 classes de ZMs; **b)** GQI para 2, 3 e 4 classes e **c)** ICVI para 2, 3 e 4 classes.

O procedimento de seleção da melhor combinação de métodos para delineamento das ZMs foi realizado em duas etapas: (i) o teste de Tukey foi aplicado para identificar se as classes geradas apresentavam diferenças significativas em relação aos valores de produtividade média normalizado; (ii) foi escolhida, entre as ZMs selecionadas, a de melhor índice GQI (quanto menor, melhor). Para as ZMs de três classes somente o delineamento EV-2 mostrou-se viável, visto que não há sentido em delinear zonas com classes que não sejam estatisticamente diferentes. Todos os delineamentos de quatro classes não apresentaram classes estatisticamente distintas, sendo desconsiderados.

## 6 CONSIDERAÇÕES FINAIS

### 6.1 Conclusões

A evolução temporal dos IVs, obtido através de imagens *Sentinel-2*, utilizando escala espacial e temporal, foi adequada para o acompanhamento da evolução da biomassa no cultivo do milho. Sendo assim, este instrumento pode integrar sistemas de monitoramento que visam identificar problemas no crescimento de plantas ou até mesmo aumentar sua produtividade. Com base nos resultados obtidos é possível afirmar que seu uso é viável para acompanhamento próximo ao tempo real, poisas imagens são disponibilizadas pela API quase em tempo real de operação, em até 5 dias, com a possibilidade de verificar valores de IVs fora do padrão. A aplicação computacional desenvolvida (ADB-RS) pode também ser utilizada para eleger cenas mais adequadas para estudos relacionados a sensoriamento remoto e imagens de satélite.

A metodologia utilizada no desenvolvimento da aplicação utilizou tecnologias emergentes na área de desenvolvimento de *software*, baseado em nuvem, sendo eficiente na gestão de dados sensoriamento remoto voltados para a agricultura de precisão. Neste trabalho, optou-se por trabalhar com os índices de vegetação NDVI, EVI e EVI-2, porém também é possível trabalhar com imagens de bandas de forma individual. Fica a critério do usuário trabalhar com índices ou bandas.

A modelagem computacional, a arquitetura desenvolvida, bem como o levantamento e estudo das bibliotecas/*frameworks* utilizados para o desenvolvimento da plataforma auxiliam para o desenvolvimento de outros *softwares* geoespaciais, com características de integração em nuvem. Atualmente é possível trabalhar com imagens de satélite *Sentinel-2* e *Landsat-8*, porém, a aplicação apresenta potencial para integrar um conjunto maior de satélites e drones.

A biblioteca GeoTools foi utilizada para realizar transformações em imagens *raster* e não apresentou problemas para a realização dessa tarefa. Outro aspecto positivo é a linguagem de programação da biblioteca; por ser uma biblioteca Java ela foi facilmente integrada ao *back-end* da aplicação computacional proposta.

O delineamento de ZMs utilizando dados de NDVI, EVI e EVI-2, gerados a partir de imagens do satélite *Sentinel-2*, mostrou alta convergência com dados de produtividade. Sendo assim, os dados de IVs utilizados nessa pesquisa podem complementar de forma eficiente seu uso no delineamento de ZMs.

Todos os delineamentos para duas classes apresentaram diferença estatística entre suas classes, sendo o melhor desempenho obtido com o uso da variável altitude no delineamento de zonas de manejo (ZMs). O único delineamento com três classes que separou estatisticamente as ZMs foi o que utilizou EVI-2. Todos os delineamentos com quatro classes foram descartados, pois não apresentaram diferença estatística significativa entre suas classes.

## **6.2 Trabalhos futuros**

Investigar o uso dos demais índices de vegetação já disponíveis no módulo computacional. Testar a sua vetorização na plataforma ADB e validar seu uso com diferentes conjuntos de dados. Gerar novos experimentos e novos delineamento de ZMs.

Integrar novas funcionalidades que possibilitem que outros tipos de imagens também sejam utilizados no módulo, como por exemplo, imagens de outros satélites e VANTs, e testar a vetorização dessas imagens na plataforma ADB-Map.

## REFERÊNCIAS

AL-GAADI, K. A.; HASSABALLA, A. A.; TOLA, E.; KAYAD, A. G.; MADUGUNDU, R.; ALBLEWI, B.; ASSIRI, F. Prediction of potato crop yield using precision agriculture techniques. **PLoS ONE**, v. 11, n. 9, p. 1–16, 2016.

ARANGO, R. B.; CAMPOS, A. M.; COMBARRO, E. F.; CANAS, E. R.; DÍAZ, I. Identification of agricultural management zones through clustering algorithms with thermal and multispectral satellite imagery. **International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems**, v. 25, n. December, p. 121–140, 2017.

ARAÚJO, J. C.; VETTORAZZI, C. A.; MOLIN, J. P. Estimativa da produtividade e determinação de zonas de manejo, em culturas de grãos, por meio de videografia aérea multiespectral. **Acta Scientiarum**, Agronomy, Maringá – PR, v. 27, n. 3, p. 437–447, 2005.

BAZZI, C. L.; JASSE, E. P.; GRAZIANO MAGALHÃES, P. S.; MICHELON, G. K.; SOUZA, E. G. DE; SCHENATTO, K.; SOBJAK, R. AgDataBox API – Integration of data and *software* in precision agriculture. **SoftwareX**, v. 10, 2019. Art. 100327.

BAZZI, C. L.; SOUZA, E. G.; URIBE-OPAZO, M. A.; NÓBREGA, L. H. P.; ROCHA, D. M. Management zones definition using soil chemical and physical attributes in a soybean area. **Engenharia Agrícola**, Jaboticabal – SP, v. 33, n. 5, p. 952–964, 2013.

BERTOLIN, A. O.; FILGUEIRAS, R.; VENANCIO, L. P.; MANTOVANI, E. C. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Revista Brasileira de Agricultura Irrigada**, Fortaleza – CE, v. 11, n. 4, p. 1627-1638, 2017.

BETZEK, N. M.; SOUZA, E. G. DE; BAZZI, C. L.; SCHENATTO, K.; GAVIOLI, A. Rectification methods for optimization of management zones. **Computers and Electronics in Agriculture**, v. 146, p. 1–11, March 2018.

BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; GAVIOLI, A.; MAGALHÃES, P. S. G. Computational routines for the automatic selection of the best parameters used by interpolation methods to create thematic maps. **Computers and Electronics in Agriculture**, v. 157, p. 49–62, February 2019.

BEZDEK, J. C. **Pattern recognition with fuzzy objective function algorithms**. New York: Plenum Press, 1981.

BORGES, L. F.; BAZZI, C. L.; SOUZA, E. G.; MAGALHÃES, P. S.; MICHELON, G. Web *software* to create thematic maps for precision agriculture. **Pesquisa Agropecuária Brasileira**, Brasília – DF, v. 55, 2020.

BOYDELL, B.; MCBRATNEY, A. B. Identifying potential within-field management zones from cotton-yield estimates. **Precision Agriculture**, v. 3, n. 1, p. 9–23, 2002.

BREUNIG, F. M.; GALVÃO, L. S.; DALAGNOL, R.; SANTI, A. L.; FLORA, D. P. DELLA; CHEN, S. Assessing the effect of spatial resolution on the delineation of management zones for smallholder farming in southern Brazil. **Remote Sensing Applications: Society and Environment**, v. 19, August 2020. Art. 100325.

BURROUGH, P. A. Mapping and map analysis: new tools for land evaluation. **Soil Use and Management**, v. 3, n. 1, p. 20–25, 1987.

CÂMARA, G. Representação computacional de dados geográficos. In: CASANOVA, M. A. et al. **Bancos de dados geográficos**. Curitiba: MundoGEO, 2005. p. 1–44.

CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V.; MEDEIROS, J. S. D. **Introdução à ciência da geoinformação**. São José dos Campos Instituto Nacional de Pesquisas Espaciais (INPE), 2001.

CHANG, D.; ZHANG, J.; ZHU, L.; GE, S. H.; LI, P. Y.; LIU, G. S. Delineation of management zones using an active canopy sensor for a tobacco field. **Computers and Electronics in Agriculture**, v. 109, p. 172–178, 2014.

CHEN, Y.; GUERSCHMAN, J. P.; CHENG, Z.; GUO, L. Remote sensing for vegetation monitoring in carbon capture storage regions: a review. **Applied Energy**, v. 240, p. 312–326, February, 2019.

CICORE, P.; SERRANO, J.; SHAHIDIAN, S. SOUZA, A.; COSTA, J. L.; SILVA, J. R. M. Assessment of the spatial variability in tall wheatgrass forage using Landsat8 satellite imagery to delineate potential management zones. **Environmental Monitoring and Assessment**, v. 188, 2016. Art. 513.

COHEN J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 1, p. 37-46, 1960.

CRUZ, S. A. B; SILVA, J. S. V; NEVES, S. M. A. S. Proposta de uso de computação em nuvem em aplicações de zoneamento. SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL, 6, 2016, Cuiabá. **Anais...** São José dos Campos: INPE; Brasília, DF: Embrapa, 2016. p. 133-140.

CZAPLEWSKI, R. L.; REICH, R. M. Expected value and variance of Moran's bivariate spatial autocorrelation statistic for a permutation test. **USDA Forest Service Rocky Mountain Forest and Range Experiment Station**, Fort Collins, CO: Research Paper, 1993.

DAMIAN, J. M.; CASTRO PIAS, O. H. DE; CHERUBIN, M. R.; FONSECA, A. Z. DA; FORNARI, E. Z.; SANTI, A. L. Applying the NDVI from satellite images in delimiting management zones for annual crops. **Scientia Agricola**, Piracicaba -SP, v. 77, n. 1, p. 1–11, 2020.

DAWIDOWICZ, A.; KULAWIAK, M.; ZYSK, E.; KOCUR-BERA, K. System architecture of an INSPIRE-compliant green cadastre system for the EU Member State of Poland. **Remote Sensing Applications: Society and Environment**, v. 20, August, 2020.

DENG, L.; MAO, Z.; LI, X.; HU, Z.; DUAN, F.; YAN, Y. UAV-based multispectral remote sensing for precision agriculture: a comparison between different cameras. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, p. 124–136, 2018.

DOBERMANN, A.; PING, J. L.; ADAMCHUK, V. I.; SIMBAHAN, G. C.; FERGUSON, R. B. Classification of crop yield variability in irrigated production fields. **Agronomy Journal**, v. 95, n. 5, p. 1105–1120, 2003.

DONG, T. et al. Using RapidEye imagery to identify within-field variability of crop growth and yield in Ontario, Canada. **Precision Agriculture**, v. 20, n. 6, p. 1231–1250, 2019.

- DONHA, A. G.; SOUZA, L. C. D. P.; SUGAMOSTO, M. L. Environmental fragility determination using decision support techniques and GIS. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande - PB, v. 10, n. 1, p. 175–181, 2006.
- DRIEMEIER, C.; LING, L. Y.; SANCHES, G. M.; PONTES, A. O.; MAGALHÃES, P. S. G.; FERREIRA, J. E. A computational environment to support research in sugarcane agriculture. **Computers and Electronics in Agriculture**, v. 130, p. 13–19, 2016.
- EVANGELIDIS, K.; NTOUROS, K.; MAKRIDIS, S.; PAPTAEODOROU, C. Geospatial services in the cloud. **Computers and Geosciences**, v. 63, p. 116–122, 2014.
- FITZ, P. R. **Geoprocessamento sem complicação**. São Paulo: Oficina de textos, 2008.
- FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. São Paulo: Oficina de textos, 2011.
- FONTANET, M.; SCUDIERO, E.; SKAGGS, T. H.; FERNÁNDEZ-GARCIA, D.; FERRER, F.; RODRIGO, G.; BELLVERT, J. Dynamic Management Zones for Irrigation Scheduling. **Agricultural Water Management**, v. 238, April 2020. Art. 106207.
- FORMAGGIO, A. R.; SANCHES, E. D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de textos, 2017.
- FRIDGEN, J. J.; KITCHEN, N. R.; SUDDUTH, K. A.; DRUMMOND, S. T.; WIEBOLD, W. J.; FRAISSE, C. W. Management Zone Analyst (MZA): *Software* for Subfield Management Zone Delineation. **Agronomy Journal**, v. 96, n. 1, p. 100–108, 2004.
- GAO, L.; WANG, X.; JOHNSON, B. A.; TIAN, Q.; WANG, Y.; VERRELST, J.; MU, X.; GU, X. Remote sensing algorithms for estimation of fractional vegetation cover using pure vegetation index values: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, p. 364–377, January 2020.
- GAVIOLI, A.; SOUZA, E. G. DE; BAZZI, C. L.; GUEDES, L. P. C.; SCHENATTO, K. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, v. 127, p. 302–310, 2016.
- GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; BETZEK, N. M. Identification of management zones in precision agriculture: An evaluation of alternative cluster analysis methods. **Biosystems Engineering**, v. 181, p. 86–102, 2019.
- GIACHETTA, R. A framework for processing large scale geospatial and remote sensing data in MapReduce environment. **Computers and Graphics (Pergamon)**, v. 49, p. 37–46, 2015.
- GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. 3. ed. São Paulo: Pearson, 2010.
- GUEDES, G. T. A. **UML 2: uma abordagem prática**. 3. ed. São Paulo: Novatec, 2018. p. 496.
- HAN, W.; DI, L.; YU, G.; SHAO, Y.; KANG, L. Investigating metrics of geospatial web services: the case of a CEOS federated catalog service for earth observation data. **Computers and Geosciences**, v. 92, p. 1–8, 2016.
- HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 2002.

HUYLENBROECK, L.; LASLIER, M.; DUFOUR, S.; GEORGES, B.; LEJEUNE, P.; MICHEZ, A. Using remote sensing to characterize riparian vegetation: a review of available tools and perspectives for managers. **Journal of Environmental Management**, v. 267, 2020. Art. 110652.

JEPPESEN, J. H.; EBEID, E.; JACOBSEN, R. H.; TOFTEGAARD, T. S. Open geospatial infrastructure for data management and analytics in interdisciplinary research. **Computers and Electronics in Agriculture**, v. 145, n. July 2017, p. 130–141, 2018.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 2008.

KALOXYLOS, A.; GROUMAS, A.; SARRIS, V.; KATSIKAS, L.; MAGDALINOS, P.; ANTONIOU, E.; POLITOPOULOU, Z.; WOLFERT, S.; BREWSTER, C.; EIGENMANN, R.; MAESTRE TEROL, C. A cloud-based farm management system: Architecture and implementation. **Computers and Electronics in Agriculture**, v. 100, p. 168–179, 2014.

KRÄMER, M.; SENNER, I. A modular *software* architecture for processing of big geospatial data in the cloud. **Computers and Graphics (Pergamon)**, v. 49, p. 69–81, 2015.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, n.1, p. 159-174, 1977.

LI, W.; WANG, S.; BHATIA, V. PolarHub: A large-scale web crawling engine for OGC service discovery in cyberinfrastructure. **Computers, Environment and Urban Systems**, v. 59, p. 195–207, 2016.

LISBOA FILHO, J.; IOCHPE, C. Introdução a sistemas de informações geográficas com ênfase em banco de dados. CONGRESSO DA SBC - Jornada de Atualização em Informática, Recife-PE, 1996. **Anais....** Recife: SBC, 1996.

MAES, W. H.; STEPPE, K. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. **Trends in Plant Science**, v. 24, n. 2, p. 152–164, 2019.

MAESTRINI, B.; BASSO, B. Predicting spatial patterns of within-field chop yield variability. **Field Crops Research**, v. 219, p. 106-112, 2018.

MANN, K. K.; SCHUMANN, A. W.; OBREZA, T. A. Delineating productivity zones in a citrus grove using citrus production, tree growth and temporally stable soil data. **Precision Agriculture**, v. 12, p. 457-472, 2011.

MANVI, S. S.; KRISHNA SHYAM, G. Resource management for Infrastructure as a Service (IaaS) in cloud computing: A survey. **Journal of Network and Computer Applications**, v. 41, n. 1, p. 424–440, 2014.

MENEZES, S. J. M. C.; RIBEIRO, C. A. A. S.; LIMA, C. A.; SOUZA, M. O. A. Geotecnologias aplicadas à gestão ambiental. **Revista Diversidade e Gestão**, Rio de Janeiro, v. 1, n. 1, p. 57-69. 2017. Volume especial. Gestão ambiental: perspectivas, conceitos e casos.

MICHELON, G. K.; BAZZI, C. L.; UPADHYAYA, S.; SOUZA, E. G.; MAGALHÃES, P. S. G.; BORGES, L. F.; SCHENATTO, K.; SOBJAK, R.; GAVIOLI, A.; BETZEK, N. M. *Software* AgDataBox-Map to precision agriculture management. **SoftwareX**, v. 10, 2019. Art. p. 100320.

MORAES NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Edgard Blucher, 2010.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa, MG: Editora UFV, 2011.

MUNNAF, M. A.; HAESAERT, G.; VAN MEIRVENNE, M.; MOUAZEN, A. M. Map-based site-specific seeding of consumption potato production using high-resolution soil and crop data fusion. **Computers and Electronics in Agriculture**, v. 178, 2020. Art. 105752.

ODEH, I. O. A.; MCBRATNEY, A. B.; CHITTLEBOROUGH, D. J. Soil pattern recognition with *fuzzy-c-means*: application to classification and soil-landform interrelationships. **Soil Science Society of America Journal**, v. 56, n. 2, p. 505–516, 1992.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. São Paulo: Thomson Learning, 2008. 528 p.

PERSECHINO, A.; ALBUQUERQUE, M. Processamento digital de imagens: conceitos fundamentais. **Monografia**. Centro Brasileiro de Pesquisas Físicas, Rio de Janeiro, v. 1, n. 4, p. 1–41, 2015.

PÔÇAS, I.; CALERA, A.; CAMPOS, I.; CUNHA, M. Remote sensing for estimating and mapping single and basal crop coefficients: a review on spectral vegetation indices approaches. **Agricultural Water Management**, v. 233, April 2020. Art. 106081.

QUEIROZ, G. R.; FERREIRA, K. R. **Tutorial sobre bancos de dados geográficos**. GeoBrasil 2006. São José dos Campos – SP: INPE, 2006. p. 57-61.

RUSPINI, E. H. A new approach to clustering. **Information and Control**, v. 15, n. 1, p. 22–32, 1969.

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BIER, V. A.; BETZEK, N. M.; GAVIOLI, A. Interpolação de dados na definição de unidades de manejo. **Acta Scientiarum**, Technology, Maringá – PR, v. 38, n. 1, p. 31–34, 2016.

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; GAVIOLI, A.; BETZEK, N. M.; BENEDEZZI, H. M. Normalization of data for delineating management zones. **Computers and Electronics in Agriculture**, v. 143, p. 238–248, February 2017.

SCIORTINO, M.; FELICE, M. DE; CECCO, L.; BORFECCHIA, F. Remote sensing for monitoring and mapping land productivity in Italy: a rapid assessment methodology. **Catena**, v. 188, May 2020. Art. 104375.

SELCUK-KESTEL, A. S.; DUZGUN, H. S.; LUTFI, O. A GIS- based *software* for lifeline reliability analysis under seismic hazard. **Computers and Geosciences**, v. 42, p. 37–46, 2012.

SEMERARO, T.; MASTROLEO, G.; POMES, A.; LUVISI, A.; GISSI, E.; ARETANO, R. Modelling *fuzzy* combination of remote sensing vegetation index for durum wheat crop analysis. **Computers and Electronics in Agriculture**, v. 156, p. 684-692, January 2019.

SEO, B.; LEE, J.; LEE, K. D.; HONG, S.; KANG, S. Improving remotely-sensed crop monitoring by NDVI-based crop phenology estimators for corn and soybeans in Iowa and Illinois, USA. **Field Crops Research**, v. 238, p. 113–128, 2019.

SON, N. T.; CHEN, C. F.; CHEN, C. R.; MINH, V. Q.; TRUNG, N. H. A comparative analysis of multitemporal MODIS EVI and NDVI data for large-scale rice yield estimation. **Agricultural and Forest Meteorology**, v. 197, p. 52–64, 2014.

SONG, M.; LI, W.; ZHOU, B.; LEI, T. Spatiotemporal data representation and its effect on the performance of spatial analysis in a cyberinfrastructure environment - A case study with raster zonal analysis. **Computers and Geosciences**, v. 87, p. 11–21, 2016.

SPADONI, G. L.; CAVALLI, A.; CONGEDO, L.; MUNAFÒ, M. Analysis of normalized difference vegetation index (NDVI) multi-temporal series for the production of forest cartography. **Remote Sensing Applications**. Society and Environment, v.20 November 2020, Art. 100419.

SUN, L.; GAO, F.; XIE, D.; ANDERSON, M.; CHEN, R.; YANG, YUN; YANG, YANG; CHEN, Z. Reconstructing daily 30 m NDVI over complex agricultural landscapes using a crop reference curve approach. **Remote Sensing of Environment**, v. 253, February 2021. Art. 112156.

SUN, Z.; DI, L.; GAIGALAS, J. SUIIS: simplify the use of geospatial web services in environmental modelling. **Environmental Modelling and Software**, v. 119, p. 228–241, September 2019.

TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. A. Management zones delineation using *fuzzy* clustering techniques in grapevines. **Precision Agriculture**, v. 14, n. 1, p. 18–39, 2013.

TANG, J.; MATYAS, C. J. Arc4nix: a cross-platform geospatial analytical library for cluster and cloud computing. **Computers and Geosciences**, v. 111, p. 159–166, February 2018.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

VALLENTIN, C.; DOBERS, E. S.; ITZEROTT, S.; KLEINSCHMIT, B.; SPENGLER, D. Delineation of management zones with spatial data fusion and belief theory. **Precision Agriculture**, v. 21, n. 4, p. 802–830, 2020.

WANG, L.; MA, Y.; YAN, J.; CHANG, V.; ZOMAYA, A. Y. Pipscloud: High performance cloud computing for remote sensing big data management and processing. **Future Generation Computer Systems**, v. 78, p. 353–368, 2018.

WANG, P.; WANG, J.; CHEN, Y.; NI, G. Rapid processing of remote sensing images based on cloud computing. **Future Generation Computer Systems**, v. 29, n. 8, p. 1963–1968, 2013.

WANG, X.; GE, L.; LI, X. Pasture monitoring using SAR with COSMO-SkyMed, ENVISAT ASAR, and ALOS PALSAR in Otway, Australia. **Remote Sensing**, v. 5, n. 7, p. 3611–3636, 2013.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: a meta-review. **Remote Sensing of Environment**, v. 236, January 2020. Art. 111402.

XIANG, L.; YU-CHUN, P.; ZHONG-QIANG, G.; CHUN-JIANG, Z. Delineation and scale effect of precision agriculture management zones using yield monitor data over four years. **Agricultural Sciences in China**, v. 6, n. 2, p. 180–188, 2007.

YANG, C. Remote sensing and precision agriculture technologies for crop disease detection and management with a practical application example. **Engineering**, v. 6, n. 5, p. 528–532, 2020.

YANG, C.; GOODCHILD, M.; HUANG, Q.; NEBERT, D.; RASKIN, R.; XU, Y.; BAMBACUS, M.; FAY, D. Spatial cloud computing: how can the geospatial sciences use and help shape cloud computing? **International Journal of Digital Earth**, v. 4, n. 4, p. 305–329, 2011.

YANG, C.; XU, Y.; NEBERT, D. Redefining the possibility of digital Earth and geosciences with spatial cloud computing. **International Journal of Digital Earth**, v. 6, n. 4, p. 297–312, 2013.

YANG, C.; YU, M.; HU, F.; JIANG, Y.; LI, Y. Utilizing cloud computing to address big geospatial data challenges. **Computers, Environment and Urban Systems**, v. 61, p. 120–128, 2017.

YOST, M. A.; KITCHEN, N. R.; SUDDUTH, K. A.; MASSEY, R. E.; SADLER, E. J.; DRUMMOND, S. T.; VOLKMANN, M. R. A long-term precision agriculture system sustains grain profitability. **Precision Agriculture**, v. 20, n. 6, p. 1177–1198, 2019.

ZHANG, H.; MA, J.; CHEN, C.; TIAN, X. NDVI-Net: A fusion network for generating high-resolution normalized difference vegetation index in remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 168, n. April, p. 182–196, 2020.

**APÊNDICES**

## APÊNDICE A INTERFACE DE LISTAGEM DE ÁREAS CADASTRADAS

Esta interface tem como objetivo listar todas as áreas de interesse cadastradas no módulo computacional. Por meio dela é possível realizar o controle de áreas.



The screenshot shows the 'AgDataBox - Sensoriamento Remoto' interface. It features a search bar labeled 'Descrição' with a 'Pesquisar' button. Below is a table with columns for 'Descrição', 'Área', and 'Imagens'. The table lists five entries: 'Teste UTFPR-SH', 'Tasca', 'Tasca Claudio', 'Tasca Sede', and 'Tasca 2'. Each entry has a 'Mapa' link and two icons (edit and delete). A 'Nova Área' button is located at the bottom left of the interface.

Descrição	Área	Imagens	
Teste UTFPR-SH	5.9811	Mapa	 
Tasca	15.0039	Mapa	 
Tasca Claudio	22.604	Mapa	 
Tasca Sede	21.6978	Mapa	 
Tasca 2	13.266	Mapa	 

**Figura 1** Listagem de áreas cadastradas.

### Operações disponíveis

**Nova Área**

Cadastrar nova área (talhão)

- Cria-se uma nova área (talhão) a partir de suas coordenadas;

**Mapa**

Buscar imagens de satélite e IVs para área selecionada

- Permite acessar as funcionalidades para buscar de imagens de satélites e gerar IVs para a área selecionada;



Editar área

- Abre o vetor de pontos da área cadastradas para ser editado;




Excluir área

- Excluir a área selecionada.

## APÊNDICE B INTERFACE DE BUSCA DE IMAGENS DE SATÉLITE E IVS

Essa interface tem como objetivo manter as imagens e IVs referentes ao talhão de interesse. Por meio dela é inserido o mapa vetorizado de dados na plataforma ADB.



**Figura 2** Seleção de imagens para serem vetorizadas e inseridas na plataforma ADB.

### Operações disponíveis

**Pesquisar**

Pesquisar imagens disponíveis

- Definido filtro de pesquisa por data;
- Definido filtro de pesquisa por IVs;
- Definida qual paleta de cores será aplicada ao IVs e exibido no mapa

**i**

Informações sobre a paleta

- Apresenta quais opções de paleta estão disponíveis para a imagem;

**Imagens**

Imagens

- Apresenta todas as imagens disponíveis;

**Estatísticas**

Estatísticas

- Apresenta as estatísticas para a imagem atual selecionada;


**Histórico**

Histórico

- Apresenta um gráfico para o período filtrado;
- Filtro de % de nuvens e satélite.

## APÊNDICE C INTERFACE DE BUSCA DE IMAGENS DE SATÉLITE

Essa interface tem como objetivo abrir a imagem selecionada em nova janela, format PNG, salvar imagem selecionada, em formato TIF ou vetorizar e inserir todas as imagens adicionadas no quadro 'Imagens selecionadas' na plataforma ADB.



**Figura 3** Salvar ou vetorizar imagens.

Operações disponíveis	
	<p>Abrir imagem em PNG</p> <ul style="list-style-type: none"> <li>Abre imagem selecionada em nova janela, em PNG</li> </ul>
	<p>Salvar imagem em TIF</p> <ul style="list-style-type: none"> <li>Salva imagem selecionada no computador local, no formato TIF;</li> </ul>
	<p>Vetorizar imagens</p> <ul style="list-style-type: none"> <li>Vetoriza as imagens que foram adicionadas ao quadro 'Imagens selecionadas', gera arquivos JSON e insere as mesmas na plataforma ADB.</li> </ul>