



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2023/09.19.20.12-TDI

**SERVIÇO WEB PARA EXTRAÇÃO DE MÉTRICAS
FENOLÓGICAS PARA APLICAÇÕES AGRÍCOLAS A
PARTIR DE GRANDES VOLUMES DE IMAGENS
ORBITAIS**

Gabriel Koyama Alves

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Karine Reis Ferreira Gomes, e Bruno Schultz, aprovada em 25 de agosto de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/49RNU3B>>

INPE
São José dos Campos
2023

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2023/09.19.20.12-TDI

**SERVIÇO WEB PARA EXTRAÇÃO DE MÉTRICAS
FENOLÓGICAS PARA APLICAÇÕES AGRÍCOLAS A
PARTIR DE GRANDES VOLUMES DE IMAGENS
ORBITAIS**

Gabriel Koyama Alves

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Karine Reis Ferreira Gomes, e Bruno Schultz, aprovada em 25 de agosto de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/49RNU3B>>

INPE
São José dos Campos
2023

Dados Internacionais de Catalogação na Publicação (CIP)

Alves, Gabriel Koyama.

Al87s Serviço web para extração de métricas fenológicas para aplicações agrícolas a partir de grandes volumes de imagens orbitais / Gabriel Koyama Alves. – São José dos Campos : INPE, 2023.

xvi + 74 p. ; (sid.inpe.br/mtc-m21d/2023/09.19.20.12-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2023.

Orientadores : Drs. Karine Reis Ferreira Gomes, e Bruno Schultz.

1. Vegetação. 2. Sensoriamento remoto. 3. Séries temporais.
4. Cubos de dados multidimensionais. I.Título.

CDU 519.246.8:528.8



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

DEFESA FINAL DE DISSERTAÇÃO GABRIEL KOYAMA ALVES BANCA Nº 228/2023, REG. 925806/2021

No dia 25 de agosto de 2023, às 09h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Computação Aplicada, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

Título: "SERVIÇO WEB PARA EXTRAÇÃO DE MÉTRICAS FENOLÓGICAS PARA APLICAÇÕES AGRÍCOLAS A PARTIR DE GRANDES VOLUMES DE IMAGENS ORBITAIS"

Membros da Banca:

Dra. Lúbia Vinhas – Presidente – INPE

Dra. Karine Reis Ferreira Gomes – Orientadora – INPE

Dr. Bruno Schultz - Orientador - Visiona Tecnologia Espacial S.A.

Dr. Marcos Adami - Membro Interno – INPE

Dr. João Francisco Gonçalves Antunes - Membro Externo - Embrapa Agricultura Digital



Documento assinado eletronicamente por **Lúbia Vinhas, Chefe da Divisão de Projeto Estratégico 2**, em 28/08/2023, às 10:12 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Adami, Pesquisador**, em 28/08/2023, às 10:23 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Karine Reis Ferreira Gomes, Tecnologista**, em 28/08/2023, às 12:07 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Bruno Schultz (E), Usuário Externo**, em 28/08/2023, às 13:53 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **João francisco gonçalves antunes (E), Usuário Externo**, em 28/08/2023, às 13:53 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **11317926** e o código CRC **3848758C**.

Referência: Processo nº 01340.007031/2023-06

SEI nº 11317926

AGRADECIMENTOS

Durante esta jornada, tive o prazer de conhecer muitas pessoas que me ajudaram imensamente ao longo do meu mestrado.

Primeiramente, desejo agradecer ao Instituto Nacional de Pesquisas Espaciais (INPE), em particular o Dr. Rafael Santos, pela valiosa oportunidade de expandir meus conhecimentos na área.

À minha família, especialmente ao meu pai Eric, por seu apoio ao longo dessa trajetória. À minha querida namorada, pela compreensão e paciência que me demonstrou ao longo das noites de estudo e dedicação.

Minha psicóloga, pelo incentivo e principalmente pelo apoio emocional durante os dias de estresse.

Gostaria de expressar minha profunda gratidão à minha orientadora, Dra. Karine R. Ferreira, e ao meu orientador, Dr. Bruno Schultz, que desempenharam papéis cruciais na minha formação e no desenvolvimento deste trabalho.

Aos membros da banca, Dra. Lúbia, Dr. João Antunes e Dr. Marcos Adami, meu sincero agradecimento por sua contribuição inestimável com seus conhecimentos.

Não posso deixar de mencionar meus colegas de trabalho e pesquisa: Bruno, Thiago, Júlio, Alexandre, Cléber e Luiz. Nossas discussões ajudaram muito meu trabalho.

A empresa em que trabalho, Visiona, e seu presidente, João, merecem um agradecimento especial pelo incentivo aos estudos, além de conceder flexibilidade de horário para aulas e reuniões.

E, por fim, quero expressar meu agradecimento a todos aqueles que me apoiaram e que possa ter esquecido de mencionar neste momento.

A todos vocês, meu mais profundo obrigado por fazerem parte dessa jornada acadêmica.

RESUMO

O estudo dos padrões de vegetação sazonal observados por sensoriamento remoto é chamado de *Land Surface Phenology* (LSP). A partir de imagens de sensoriamento remoto, é possível obter métricas usadas para o monitoramento fenológico, que auxiliam no entendimento da dinâmica da vegetação e na tomada de decisão. Existem diferentes métodos presentes na literatura para a extração dessas métricas a partir de imagens de satélites, como os baseados em limiares, detecção de mudança e abordagens empíricas. No entanto, um dos desafios é a extração dessas métricas a partir dos grandes volumes de imagens disponibilizadas atualmente por diferentes provedores. Especialistas se deparam com limitações de hardware para processar esse grande volume de dados em computadores pessoais. Para isso, neste trabalho foi desenvolvido um serviço web, chamado *Web Phenological Metrics Service* (WPMS), para extração de métricas fenológicas a partir de grandes volumes de imagens modeladas como cubos de dados multidimensionais e de séries temporais de índices de vegetação do projeto Brazil Data Cube (BDC) do Instituto Nacional de Pesquisas Espaciais (INPE). Esse serviço segue uma arquitetura “cliente-servidor”, processando todo o dado do lado do servidor e retornando para o cliente apenas o resultado do processamento. Usando esse serviço, um especialista pode extrair métricas a partir de grandes volumes de imagens sem se preocupar com limitações de processamento e com instalações de pacotes e sistemas em seu computador pessoal. Para este trabalho, foi feito um estudo que incluiu a revisão da literatura existente e análise de diferentes ferramentas e softwares utilizados neste contexto, com o objetivo de escolher aquele que melhor se adequasse na construção do serviço. Durante os estudos e análises, o pacote em R *CropPhenology* foi escolhido para a extração das métricas fenológicas. No entanto, durante os testes nos dados de campo, identificou-se uma limitação no pacote em relação à detecção de ciclos duplos de cultura em séries temporais anuais. Em resposta a essa limitação, foi necessária uma customização no pacote a fim de detectar e distinguir os diferentes ciclos, resultando na criação do método denominado *Double CropPhenology*. O serviço inclui tanto o *endpoint* para extração de métricas do pacote original quanto o modificado. Por fim, os resultados obtidos pelo serviço WPMS e o sistema para visualização se mostraram satisfatórios e útil para o campo de extrações de métricas fenológicas com foco na agricultura, contribuindo para a tomada de decisões mais informadas.

Palavras-chave: vegetação, sensoriamento remoto, séries temporais, cubos de dados multidimensionais.

WEB SERVICE FOR EXTRACTING PHENOLOGICAL METRICS FOR AGRICULTURAL APPLICATIONS FROM LARGE VOLUMES OF ORBITAL IMAGES

ABSTRACT

The study of seasonal vegetation patterns observed by remote sensing is called Land Surface Phenology (LSP). From remote sensing images, it is possible to obtain metrics used for phenological monitoring, which help in understanding vegetation dynamics and in decision making. There are different methods present in the literature for extracting these metrics from satellite images, such as those based on thresholds, change detection and empirical approaches. However, one of the challenges is extracting these metrics from the large volumes of images currently available from different providers. Experts are faced with hardware limitations to process this large volume of data on personal computers. To this end, in this work a web service was developed, called Web Phenological Metrics Service (WPMS), to extract phenological metrics from large volumes of images modeled as multidimensional data cubes and time series of vegetation indices. of the Brazil Data Cube (BDC) project of the National Institute for Space Research (INPE). This service follows a “client-server” architecture, processing all data on the server side and returning only the processing result to the client. Using this service, a specialist can extract metrics from large volumes of images without worrying about processing limitations and installing packages and systems on their personal computer. For this work, a study was carried out that included a review of existing literature and analysis of different tools and software used in this context, with the aim of choosing the one that best suited the construction of the service. During the studies and analyses, the R package CropPhenology was chosen to extract phenological metrics. However, during testing on field data, a limitation in the package was identified regarding the detection of double crop cycles in annual time series. In response to this limitation, it was necessary to customize the package in order to detect and distinguish the different cycles, resulting in the creation of the method called Double CropPhenology. The service includes both endpoint for extracting metrics from the original and modified packages. Finally, the results obtained by the WPMS service and the visualization system proved to be satisfactory and useful for the field of extracting phenological metrics with a focus on agriculture, contributing to more informed decision-making.

Keywords: vegetation, remote sensing, phenological metrics, multidimensional data cubes.

LISTA DE FIGURAS

	<u>Pág.</u>	
2.1	Arquitetura para geração do cubo de dados.	7
2.2	Exemplo do método <i>threshold-based</i>	9
2.3	Exemplo de métodos baseados em <i>change detection</i>	9
2.4	Métodos para análise das fenofases de culturas agrícolas em séries temporais de EVI.	10
2.5	Série temporal de EVI filtrada para um talhão de soja no Paraná.	10
2.6	Métricas fenológicas TIMESAT.	12
2.7	Métricas fenológicas <i>CropPhenology</i>	13
2.8	Arquitetura Cliente x Servidor.	16
3.1	Arquitetura do serviço WPMS.	19
3.2	Área de Estudo com Talhões Agrícolas nas Regiões Sul e Norte dos Estados do Maranhão (MA) e Piauí (PI) e Gráficos de Área Plantada e Rendimento Médio de Soja nos Estados.	23
3.3	Descrição visual do manejo adotado na prática da agricultura da soja nas chapadas dos estados do Maranhão e Piauí.	24
3.4	Eventos observados durante as atividades de campo.	25
3.5	Método utilizado para coleta dos dados em campo.	26
4.1	Exemplo da documentação das principais operações disponíveis no serviço web.	30
4.2	Exemplo da documentação das operações auxiliares disponíveis no serviço web.	31
4.3	Esquema resposta da operação <i>single-phenology</i>	32
4.4	Esquema resposta da operação <i>single-phenology-ts</i> e <i>double-phenology-ts</i>	32
4.5	Módulos Visiona.	34
4.6	Interface do módulo de extração de métricas fenológicas com mapa de fundo e menu lateral.	35
4.7	Interface web do módulo de extração de métricas fenológicas - Etapa 1: Upload de área de monitoramento.	36
4.8	Interface web do módulo de extração de métricas fenológicas - Exemplo de áreas cadastradas.	37
4.9	Interface web do módulo de extração de métricas fenológicas - Exemplo de seleção de área.	37

4.10	Extração de séries temporais de área selecionada - Interface web do módulo de extração de métricas fenológicas.	38
4.11	Opção de agregação de dados zonais e índice de vegetação - Interface do módulo de extração de métricas fenológicas.	39
4.12	Série temporal extraída de área monitorada - Interface web do módulo de extração de métricas fenológicas.	40
4.13	Extração de métricas fenológicas - Interface web do módulo de extração de métricas fenológicas.	41
4.14	Resultados da extração de métricas fenológicas com o método <i>CropPhenology</i> - Interface web do módulo de extração de métricas fenológicas.	41
4.15	Resultados da extração de métricas fenológicas com o método <i>Double CropPhenology</i> - Interface web do módulo de extração de métricas fenológicas.	42
4.16	Séries temporais NDVI e EVI e métricas fenológicas.	43
4.17	Comparação das métricas fenológicas para diferentes operadores zonais.	45
4.18	Séries temporais de NDVI e EVI com um ciclo anual e métricas fenológicas extraídas.	46
4.19	Séries temporais NDVI e EVI e métricas fenológicas.	47
4.20	Comparação das métricas fenológicas para diferentes operadores zonais.	49
4.21	Relação de Pearson entre a variável Produtividade Sc/ha e as métricas fenológicas agrupadas por média como operador zonal em ordem. Os valores são apresentados em ordem crescente de correlação.	51
4.22	Correlação de Pearson entre produtividade e métricas fenológicas (Média).	51
4.23	Correlação de Pearson entre produtividade e métricas fenológicas (Mínimo).	52
4.24	Correlação de Pearson entre produtividade e métricas fenológicas (Máxima).	52
4.25	Correlação de Pearson entre produtividade e métricas fenológicas (Mediana).	52
4.26	Correlação de Pearson entre produtividade e métricas fenológicas (Desvio Padrão).	52
4.27	Relação entre atributos agrícolas: TINDVI, Graos_haK e ProdScHa.	53
4.28	Relação entre atributos agrícolas: GreenUpSlope, Graos_haK e ProdScHa.	53
4.29	Relação entre atributos agrícolas: BrownDownSlope, Graos_haK e ProdScHa.	54

LISTA DE TABELAS

	<u>Pág.</u>
2.1	Cubos de dados do BDC e suas informações. 6
2.2	Métricas LSP. 7
2.3	Métricas fenológicas do pacote <i>CropPhenology</i> e suas descrições. 14
2.4	Tabela de comparação das ferramentas TIMESAT, Sen2Agri e <i>Greenbrown</i> . 15
3.1	Máscara de nuvem Sentinel2 SCL. 20
4.1	Tabela de <i>endpoints</i> principais relacionados à extração de métricas fenológicas. 30
4.2	Tabela de <i>endpoints</i> auxiliares para funções adicionais. 31
4.3	Tabela de especificações da máquina de teste. 33
4.4	Tabela de desempenho de processamento por <i>endpoint</i> 33
4.5	Métricas Fenológicas. 43
4.6	Tabela de métricas fenológicas para as séries temporais de NDVI e EVI. . 44
4.7	Tabela de métricas fenológicas para diferentes operadores zonais NDVI. . 45
4.8	Tabela de métricas fenológicas para diferentes operadores zonais EVI. . . 46
4.9	Tabela de métricas fenológicas para as séries temporais de NDVI e EVI. . 48
4.10	Tabela de métricas fenológicas para diferentes operadores zonais NDVI. . 49
4.11	Tabela de métricas fenológicas para diferentes operadores zonais EVI. . . 50
4.12	Tabela de exemplo das métricas fenológicas extraídas pelos métodos e dados de campo. 55
4.13	Resultados da análise de concordância dos ciclos fenológicos 55
A.1	Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI. 68
A.2	Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI. 69
A.3	Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI. 70
A.4	Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI. 71
A.5	Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI. 72
A.6	Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI. 73

A.7 Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.	74
--------------------------------------------------------------------------------------------	----

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Hipótese	3
1.2 Objetivo geral	3
1.3 Objetivos específicos	3
2 REVISÃO BIBLIOGRÁFICA	5
2.1 Cubos de dados e séries temporais de imagens de satélites	5
2.2 Métricas fenológicas	6
2.3 Métodos de extração de métricas fenológicas	8
2.4 Ferramentas para extração de métricas fenológicas	9
2.5 Recursos e estruturas computacionais	16
2.5.1 Arquitetura de aplicação	16
2.5.2 Serviços web	16
2.5.3 Integração de tecnologias computacionais	17
3 MATERIAIS E MÉTODOS	19
3.1 Arquitetura do serviço WPMS	19
3.2 Estudo de caso: área de estudo	22
3.2.1 Estudo de caso: amostras coletadas em campo para validação do método de extração	25
3.3 Método para validação com dados coletados em campo	27
4 RESULTADOS E DISCUSSÕES	29
4.1 Serviço WPMS	29
4.2 Desempenho de processamento	33
4.3 Sistema web para análise e visualização dos resultados	34
4.4 Análise <i>CropPhenology</i>	42
4.5 Análise <i>Double CropPhenology</i>	47
4.6 Análise produtividade calculada x coletadas em campo	50
4.7 Análise comparativa dos métodos <i>CropPhenology</i> e <i>Double CropPhenology</i> : verificação da conformidade dos ciclos fenológicos com dados de campo	54
4.8 Contribuições da dissertação	56

5 CONCLUSÕES	57
REFERÊNCIAS BIBLIOGRÁFICAS	59
APÊNDICE A	67

1 INTRODUÇÃO

Fenologia é o estudo da sazonalidade dos eventos cíclicos de vida das espécies. Nos sistemas agrícolas, o conhecimento sobre a fenologia das culturas é muito útil para definir, por exemplo, o gerenciamento de fertilizantes, a detecção de estresse, a programação da irrigação e a operação da colheita (ZENG et al., 2020; DIAO; LI, 2022; BERGER et al., 2022). Além disso, outras medidas inferidas pela fenologia, como a taxa de crescimento, a produção de biomassa e a quantidade de produção, são importantes para avaliar o desempenho das culturas, o balanço de carbono e a eficácia das práticas agrícolas empregadas (MATESE et al., 2019; GARCÍA-MOZO et al., 2010; WHITE et al., 2009; LOBELL et al., 2014).

Os métodos de estimativa da fenologia são ajustados para caracterizar mudanças distintas nas propriedades biofísicas ou bioquímicas do dossel que tendem a estar conectadas com as transições de fenofases da cultura (DIAO; LI, 2022). Neste sentido, as séries temporais de índices de vegetação calculadas a partir de dados de observação da terra de satélites, como MODIS, PROBA-V, Landsat, Sentinel e CBERS, são amplamente exploradas (GALFORD et al., 2008; ATZBERGER, 2013; RIVAS et al., 2021; CHAVES et al., 2021).

Pixels de baixa resolução espacial podem conter uma matriz heterogênea de cultivos agrícolas com cronogramas variados de plantio e colheita, o que confunde o sinal fenológico da cultura e dificulta a conexão com observações fenológicas (WHITE et al., 2009; DIAO; LI, 2022). Pixels de média resolução espacial apresentam uma boa performance em escalas mais finas, no entanto, podem resultar em séries temporais ruidosas devido à presença de nuvens, o que prejudica a avaliação das fenofases das culturas, que correspondem a diferentes estágios de desenvolvimento (SIMOES et al., 2021; RIVAS et al., 2021; DIAO; LI, 2022). Técnicas de extração de métricas fenológicas tendem a auxiliar no uso e interpretação das séries temporais de média resolução de forma apropriada, o que garante uma relação entre as informações obtidas na cultura em campo e os dados fornecidos pelos sistemas de sensores/satélites (ARAYA et al., 2017; ZHAO et al., 2012).

Na agricultura as datas de início e fim de cada fase fenológica são medidas importantes para avaliar o desempenho das culturas e a eficácia das práticas agrícolas (MATESE et al., 2019; GARCÍA-MOZO et al., 2010; WHITE et al., 2009). *Land Surface Phenology* (LSP) representa a fenologia da vegetação medida a partir de imagens de sensoriamento remoto (NOORMETS, 2009). A maioria das técnicas de LSP extraem métricas relacionadas ao crescimento e desenvolvimento da vegetação a partir

de séries temporais de índice de vegetação. Alguns exemplos dessas métricas estão associados a fases estratégicas do crescimento das culturas agrícolas, como a emergência, o máximo desenvolvimento vegetativo, o fim do crescimento e a duração do ciclo das culturas (ZENG et al., 2020).

O TIMESAT e o SEN2AGRI (JÖNSSON; EKLUNDH, 2004; SEN2AGRI, 2019) são exemplos de sistemas usados para extração de métricas fenológicas a partir de imagens de satélites. Já o *CropPhenology* e o *Phenofit* (ARAYA et al., 2018; ZHANG et al., 2018; FORKEL et al., 2013) são exemplos de pacotes na linguagem R que são capazes de extrair métricas fenológicas para agricultura, enquanto o *GreenBrown* é utilizado para análise da fenologia da vegetação natural, ambos a partir de séries temporais de índice de vegetação. O pacote *CropPhenology* é capaz de extrair 15 métricas fenológicas baseadas em séries temporais de imagens ou em um conjunto de imagens multi-temporais (ARAYA et al., 2018).

Recentemente, plataformas orbitais de observação da Terra têm produzido grandes volumes de imagens com diferentes resoluções espaciais. O programa Copernicus da Comissão Europeia, por exemplo, produz aproximadamente 10 TB de dados do satélite Sentinel por dia (KEMPENEERS; SOILLE, 2017). Portanto, um dos desafios enfrentados atualmente é a extração de métricas fenológicas a partir desse grande volume de imagens (DIAO; LI, 2022).

O objetivo deste trabalho é desenvolver um serviço web, denominado *Web Phenological Metric Service* (WPMS), para a extração de métricas fenológicas a partir de grandes volumes de imagens modeladas como cubos de dados de observação da Terra e séries temporais de índices de vegetação, com enfoque em aplicações agrícolas. Esse serviço segue uma arquitetura “cliente-servidor”, que permite o processamento dos dados no servidor, sem a necessidade de download por parte do cliente para sua máquina pessoal. Com o uso desse serviço, um especialista poderá extrair métricas de grandes volumes de imagens sem se preocupar com limitações de processamento e instalações de pacotes e sistemas em seu computador pessoal.

O desenvolvimento de componentes de software como serviços web oferece diversas vantagens, tais como facilidade de uso e interoperabilidade entre sistemas. Esses serviços facilitam a integração entre diferentes linguagens de programação, como R e Python, e diferentes tipos de aplicativos clientes (VINHAS et al., 2017). Além disso, esses serviços disponibilizam recursos com alto nível de abstração para os usuários, o que evita que eles precisem lidar com questões relacionadas ao processamento em

seus próprios computadores, à instalação de softwares ou ao ambiente de programação.

Nesse contexto, este trabalho descreve o serviço web proposto, incluindo sua arquitetura e implementação, utilizando os dados do projeto *Brazil Data Cube* (BDC) do Instituto Nacional de Pesquisas Espaciais (INPE) e os resultados alcançados até o momento.

1.1 Hipótese

A hipótese dessa dissertação é que o serviço WPMS irá facilitar e tornar mais eficiente o processo de extração de métricas fenológicas a partir de grandes volumes de imagens de sensoriamento remoto. Esse serviço possibilita o processamento desse grande volume de dados do lado do servidor, usando todo seu poder computacional sem a necessidade de transferência desses dados para o computador pessoal do usuário. Além disso, o usuário não precisa se preocupar com instalações de sistemas em seu computador pessoal.

1.2 Objetivo geral

O objetivo geral deste trabalho é desenvolver o serviço WPMS a partir de cubos de dados de observação da terra e séries temporais de índices de vegetação, com foco em aplicações agrícolas.

1.3 Objetivos específicos

- a) Estudar diferentes métodos, técnicas e pacotes de software para extração de métricas fenológicas a partir de séries temporais de imagens.
- b) Desenvolver um serviço web para extração das métricas fenológicas a partir de séries temporais de índices de vegetação.
- c) Projetar um *plugin* com interface gráfica para visualizar as métricas extraídas em uma plataforma web.
- d) Realizar testes e validar o *plugin* utilizando dados empíricos coletados em campo.

2 REVISÃO BIBLIOGRÁFICA

2.1 Cubos de dados e séries temporais de imagens de satélites

A partir de imagens de satélites, é possível extrair índices de vegetação através de cálculos nas bandas de imagens de satélite. Índices de vegetação são indicativos da cobertura de vegetação verde, atividade fotossintética e biomassa verde, como, por exemplo, o *Normalized Difference Vegetation Index* (NDVI) (PETTORELLI, 2013), o *Enhanced Vegetation Index* (EVI) (HQ, 1995), o *Soil-Adjusted Vegetation Index* (SAVI) (HUETE, 1988), entre outros.

O termo cubo de dados refere-se a um conjunto de séries temporais de imagens associadas a pixels alinhados espacialmente (APPEL; PEBESMA, 2019). Cada elemento de um cubo de dados de observação da Terra, *Earth Observation* (EO), tem duas dimensões espaciais e uma dimensão temporal e está associado a um conjunto de valores (FERREIRA et al., 2020).

O BDC é um projeto de pesquisa do INPE que está produzindo cubo de dados a partir de grandes volumes de imagens de sensoriamento remoto de média resolução para todo o território nacional. Os dados produzidos incluem coleções de dados prontos para análise (Analysis-Ready Data – ARD). Siqueira et al. (2019) define ARD como "dados de satélite processados de acordo com um conjunto mínimo de requisitos e organizados em um formato que permite análise imediata com um mínimo de esforço adicional do usuário e interoperabilidade ao longo do tempo e com outros conjuntos de dados". O ARD é gerado através de várias etapas de processamento, desde a aquisição dos dados brutos do satélite, a conversão para reflectância no topo da atmosfera (TOA) e, por fim, a reflectância da superfície da Terra (GIULIANI et al., 2017).

Além disso, o BDC também gera cubos de dados multidimensionais e mosaicos a partir de imagens dos satélites CBERS-4/4A, Sentinel-2 e Landsat-8. A plataforma computacional é composta por serviços web, aplicativos de software e ambientes de computação iterativa. Usando inteligência artificial, aprendizado de máquina e análise de séries temporais de imagens, mapas de uso e cobertura da Terra estão sendo produzidos a partir desses cubos de dados.

Os dados EO são coletados por meio de sensores orbitais que revisitam o mesmo local sobre a superfície da Terra em períodos diferentes, gerando assim sequências de imagens do mesmo local ao longo do tempo. Séries temporais derivadas desses

dados são muito úteis para investigar a dinâmica do ambiente ao longo do tempo (FERREIRA et al., 2020; SIMOES et al., 2021), inclusive para o sensoriamento de sistemas agrícolas (CHAVES et al., 2021). A Tabela 2.1 mostra as coleções de dados EO disponíveis no BDC¹.

Tabela 2.1 - Cubos de dados do BDC e suas informações.

Cubo	Satelite	Sensor	RE (m)	CT
CB4_64_16D_STK1	CBERS4	AWFI	64	16 dias
CB4MUX_20_1M_STK1	CBERS4	MUX	20	1 mês
LC8_30_16D_STK1	Landsat8	OLI	30	16 dias
MOD13Q16	TERRA	MODIS	250	16 dias
MYD13Q16	AQUA	MODIS	250	16 dias
S216D2	Sentinel 2A/2B	MSI	10	16 dias

Lista de cubos de dados do BDC, incluindo informações sobre o satélite, os sensores utilizados, a resolução espacial e o tempo de composição temporal para cada cubo de dados.
1

A Figura 2.1 mostra o processo para a criação do cubo de dados. No primeiro passo, é feita a aquisição dos dados, fazendo a coleta diretamente dos fornecedores originais de cada satélite. Em seguida, com o objetivo de gerar dados *Analysis Ready Data* (ARD), dados de satélite prontos para análise, é realizada a correção atmosférica. Após isso, os processos *warping* e *Temporal Composition* mesclam as imagens em um mosaico e definem a abordagem para selecionar ou gerar um valor de pixel válido no tempo, de acordo com funções de avaliação.

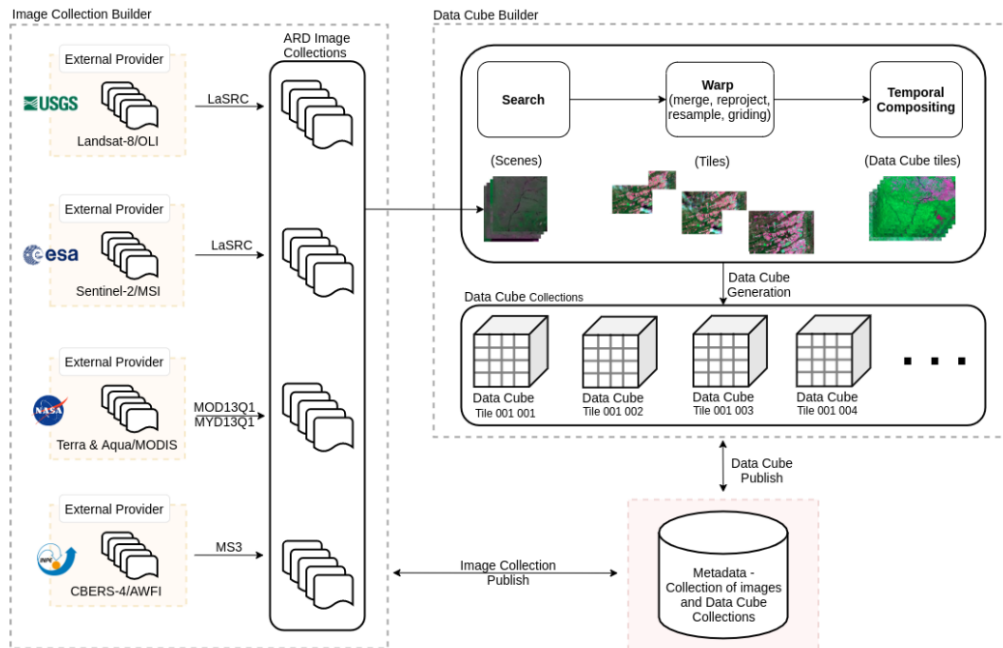
2.2 Métricas fenológicas

LSPs são normalmente associadas a mudanças gerais na vegetação ao longo dos anos e podem ser interpretadas a partir de séries temporais de dados de sensoriamento remoto (ZENG et al., 2020). A Tabela 2.2 mostra as principais métricas usadas nas técnicas de extração: *Start of Season* (SOS) representa o início do ciclo, *Peak of Season* (PEAK) o máximo vigor vegetativo, *End of Season* (EOS) retrata o final do ciclo e *Length of Season* (LOS) a duração do ciclo (ZENG et al., 2020).

A partir de densas séries de índices de vegetação, é possível caracterizar ou representar períodos relacionados às fenofases de uma cultura agrícola, como o início da

¹Disponível em: <https://brazil-data-cube.github.io/products/cube-collections.html>

Figura 2.1 - Arquitetura para geração do cubo de dados.



Aquisição de dados, processo ARD e geração do cubo de dados.
 Fonte: Ferreira et al. (2020).

emergência, o máximo vigor do dossel, o início da senescência e a duração do ciclo da cultura (ZHANG et al., 2021). Também é possível caracterizar sutis diferenças interanuais de fitofisionomias a partir da representação do início da estação chuvosa, final da estação chuvosa, início da estação seca, final da estação seca, relação entre o início da estação seca e chuvosa, entre outros (HADDAD et al., 2022).

Tabela 2.2 - Métricas LSP.

Sigla	Nome	Descrição
SOS	Start of Season (Início do ciclo)	Data do início da aquisição do ciclo.
PEAK	Peak of Season (Pico do ciclo)	Data de aquisição derivada do valor máximo de NDVI do ciclo.
EOS	End of Season (Fim do ciclo)	Data de aquisição do fim do ciclo.
LOS	Length of Season (Duração do ciclo)	Período de duração entre o início e o fim do ciclo.

Fonte: Zeng et al. (2020).

Na agricultura, de acordo com a literatura, o uso de séries temporais de índices de vegetação proporcionou resultados para diferentes finalidades, incluindo:

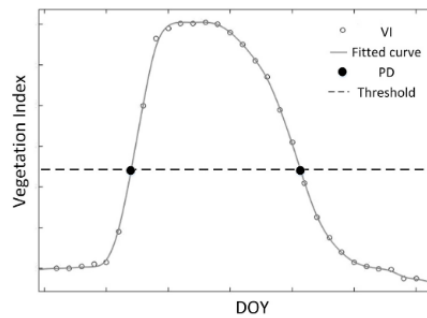
- a estimativa da data de plantio e colheita de soja (ADAMI, 2010; AMHERDT et al., 2021; ZHANG et al., 2021);
- a classificação de soja por dados ópticos (ZHONG et al., 2016) ou radar (WOŹNIAK et al., 2022) em diferentes sistemas de cultivo;
- a análise de cultivos em regime *single* ou *double-crop* (SANO et al., 2023) e plantios em *double-crop*, com soja (CHAVES et al., 2021);
- a estimativa de produtividade da soja em escala regional (STEPANOV et al., 2020) ou em escala local (GUSSO et al., 2017; SONG et al., 2022);
- análise dos estádios fenológicos da soja e dinâmica da fenologia (SAKAMOTO et al., 2010; FONTANA et al., 2015; YANG et al., 2021).

De acordo com Picoli et al. (2018) e Chaves et al. (2021), a extração de padrões temporais a partir de métricas fenológicas aumenta a detecção de diferenças sutis entre as culturas agrícolas e outras classes de uso e ocupação do solo. Essas diferenças possibilitam o melhor emprego de técnicas para estimativa de produtividade (SONG et al., 2022) e para a detecção de semeadura e colheita das culturas agrícolas (ARAYA et al., 2017; ZHANG et al., 2021), por exemplo.

2.3 Métodos de extração de métricas fenológicas

Atualmente existem diversos métodos propostos para extração de métricas que podem ser classificados em duas categorias: métodos baseados em limiares e métodos de detecção de alterações nos índices de vegetação (REED et al., 2009). Os métodos baseados em limiares, *threshold-based*, como mostrado na Figura 2.2, são abordagens mais simples, assumindo os estágios fenológicos através de valores predefinidos das curvas de índice de vegetação (VI). Existem dois tipos nesta categoria: *threshold-fixed*, limiares fixos, e *threshold-dynamic*, limiares dinâmicos. No primeiro, é definido um valor único e arbitrário para definir o SOS, e o EOS geralmente é um valor definido através de algum cálculo a partir das séries temporais, como média a longo prazo ou a mediana. Já a detecção por alteração de índice de vegetação determina as datas fenológicas detectando diretamente as características variáveis da curva da série temporal (REED et al., 2009). Os métodos desta categoria são: *moving average*, *maximum and minimum values*, *largest derivative*, como apresentado na Figura 2.3.

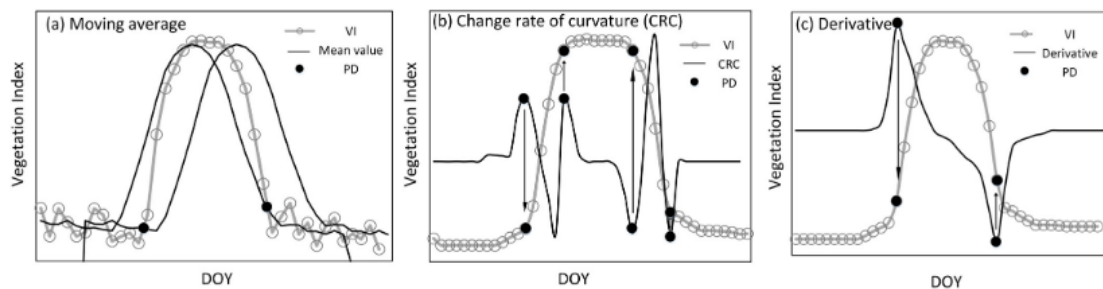
Figura 2.2 - Exemplo do método *threshold-based*.



Esquema mostrando como as datas fenológicas (PD), são extraídas por métodos de *threshold*. As PD são extraídas quando os valores de VI atingem os limiares fixos ou dinâmicos predefinidos.

Fonte: Zeng et al. (2020).

Figura 2.3 - Exemplo de métodos baseados em *change detection*.



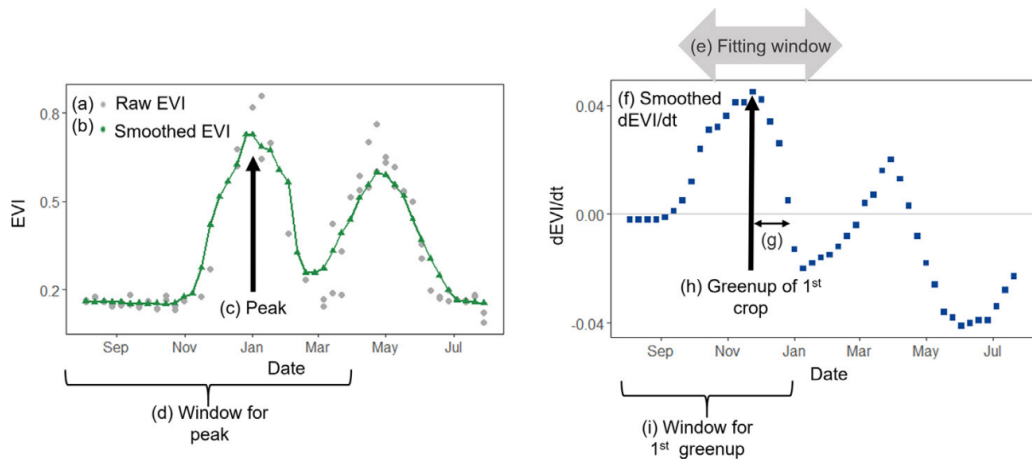
Esquema mostrando como as datas fenológicas (PD) são extraídas detectando as características de mudança da curva de série temporal VI usando: (a) método de média móvel, (b) valores máximos e mínimos na taxa de mudança na curvatura e (c) o maior derivada.

Fonte: Zeng et al. (2020).

2.4 Ferramentas para extração de métricas fenológicas

Para a agricultura, normalmente, a extração das métricas fenológicas se dá pela definição das fenofases das culturas (ZHANG et al., 2021). No estado de Mato Grosso, por exemplo, é possível identificar dois ciclos agrícolas distintos (primeira e segunda safra) em um mesmo ano agrícola, como apresentado na Figura 2.4.

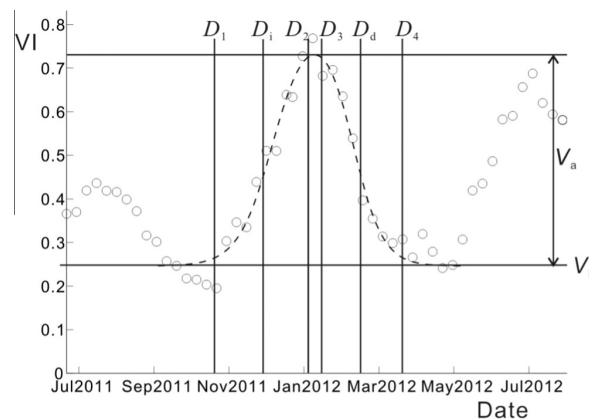
Figura 2.4 - Métodos para análise das fenofases de culturas agrícolas em séries temporais de EVI.



Fonte: Zhang et al. (2021).

Zhong et al. (2016) comenta que a evolução dos estádios de desenvolvimento das culturas agrícolas apresenta variabilidades inter-anuais e inter-regionais, e determinados sinais específicos podem ser caracterizados apenas em fases restritas do calendário das culturas agrícolas. A Figura 2.5 ilustra métricas fenológicas extraídas na fenofase da primeira safra, a partir do conhecimento dos sistemas agrícolas utilizados para a soja e milho de primeira safra no estado do Paraná.

Figura 2.5 - Série temporal de EVI filtrada para um talhão de soja no Paraná.



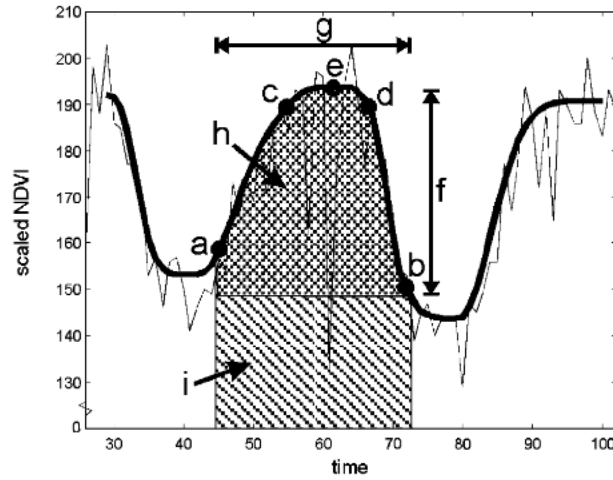
D_1 , D_2 , D_3 e D_4 representam as quatro datas em que a segunda derivada da curva atinge o máximo ou mínimo local, representando as datas de início e término dos dois segmentos. Fonte: Zhong et al. (2016).

Para as finalidades descritas acima, os dados brutos obtidos pelo MODIS ou por sensores Landsat-like são geralmente ruidosos e, portanto, não são usados diretamente para análises (PICOLI et al., 2018). Na agricultura tropical, é necessária a suavização das séries temporais de índices de vegetação para adequar e homogeneizar o ruído, uma vez que o ruído pode reduzir os padrões temporais presentes nas séries (ATZBERGER, 2013).

Para a suavização, interpolação e suavização das séries temporais, diferentes tipos de técnicas e filtros podem ser empregados (SAKAMOTO et al., 2010; ATZBERGER; EILERS, 2011; BROWN et al., 2013; KASTENS et al., 2017). Para os sistemas de cultivos em duas safras localizados na agricultura tropical, recomenda-se o uso do filtro Whittaker smoothing (ATZBERGER; EILERS, 2011; ATZBERGER, 2013; FERNANDES et al., 2018). A partir da diminuição dos ruídos das séries temporais, é possível realizar a extração das métricas fenológicas de forma apropriada (ZHONG et al., 2016; ZHANG et al., 2021).

Wang et al. (2016) e Picoli et al. (2018) enfatizam o uso do software TIMESAT para a extração das métricas fenológicas de índices de vegetação (JÖNSSON; EKLUNDH, 2004). Uma das principais características do TIMESAT é ser um software padrão que tem a capacidade de ajustar uma curva de suavização aos dados de séries temporais, o que permite remover ruídos e inconsistências nos dados, além de possibilitar a detecção de pontos de mudança na série temporal, como mostra a Figura 2.6. No entanto, é um software que foi desenvolvido em 2007 na linguagem FORTRAN90, que passou por várias atualizações, é de propriedade privada e sem possibilidade de customizações pelo usuário.

Figura 2.6 - Métricas fenológicas TIMESAT.



Alguns dos parâmetros de sazonalidade calculados no TIMESAT: (a) início da temporada, (b) final da temporada, (c) nível de 90% à esquerda, (d) nível de 90% à direita, (e) pico, (f) amplitude, (g) duração da estação, (h) integral sobre a estação de crescimento dando área entre função ajustada e média dos valores mínimos esquerdo e direito, (i) integral sobre estação de crescimento dando área entre função ajustada e nível zero.

Fonte: Jönsson and Eklundh (2004).

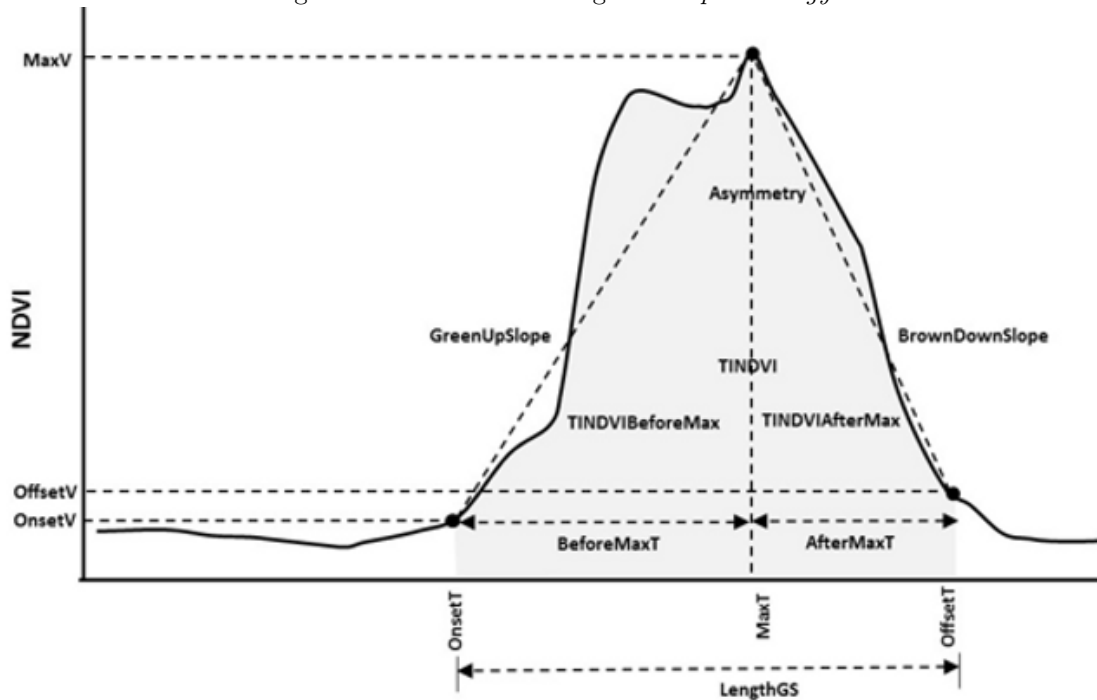
Outro software utilizado para extração de métricas fenológicas para a agricultura é o Sen2Agri (PATIL et al., 2019; GENG et al., 2020). O Sen2Agri é um sistema orquestrador que integra várias ferramentas e softwares para o processamento de imagens Sentinel-2A/B e da família Landsat (UDROIU et al., 2019). O produto gerado por meio da análise de métricas fenológicas no Sen2Agri é o *Vegetation Status*, que utiliza índices de vegetação como o NDVI e a Anomalia de Temperatura para detectar variações na quantidade e qualidade da vegetação ao longo do tempo (BALI et al., 2019).

Greenbrown, *Phenofit* e *CropPhenology* são pacotes de software livre e de código aberto, desenvolvidos em diferentes linguagens computacionais de fácil entendimento, focados em extrair informações sobre a fenologia da vegetação a partir de séries temporais de índices de vegetação (ARAYA et al., 2017; HADDAD et al., 2022). Dentre eles, o *CropPhenology* tem sido amplamente explorado e existe uma comunidade científica ativa para melhorias nos códigos e funções do pacote.

Pelo *CropPhenology*, é possível extrair 15 métricas fenológicas com base em índices de vegetação obtidos por satélite ao longo da temporada de cultivo: *OnsetV*, *OnsetT*, *MaxV*, *MaxT*, *OffsetV*, *OffsetT*, *LengthGS*, *BeforeMaxT*, *AfterMaxT*, *GreenUpSlope*,

BrownDownSlope, *TINDVIBeforeMax*, *TINDVIAfterMax*, *TINDVI* e *Asymmetry* (ARAYA et al., 2018). A Figura 2.7 mostra a representação das métricas na curva NDVI, e a Tabela 2.3 representa a sua descrição.

Figura 2.7 - Métricas fenológicas *CropPhenology*.



Fonte: Araya et al. (2018).

O pacote *CropPhenology* tem se mostrado uma ferramenta útil e eficiente para a extração de métricas fenológicas para agricultura a partir de índices de vegetação obtidos por sensoriamento remoto. Isso pode ser comprovado pelo número crescente de artigos que o citam em suas metodologias de análise de dados.

No estudo de Kyere et al. (2020), foi realizada a discriminação de culturas agrícolas em uma região heterogênea de baixa montanha com base em dados de satélite multitemporais e multi-sensores. O autor utilizou o pacote *CropPhenology* para extrair métricas fenológicas das imagens de satélite. Foram aplicados algoritmos de aprendizado de máquina, como o *Random Forest*, em combinação com essas métricas para discriminar 13 tipos de culturas. Um total de 15 métricas fenológicas, juntamente com 48 informações espectrais e 2 informações topográficas, foram usadas como preditores no modelo.

Tabela 2.3 - Métricas fenológicas do pacote *CropPhenology* e suas descrições.

Métrica	Descrição
OnsetT	Dia do ano em que ocorre a emergência da cultura
OnsetV	Valor do índice de vegetação correspondente a OnsetT
OffsetT	Dia do ano em que a cultura é colhida
OffsetV	Valor do índice de vegetação correspondente a OffsetT
MaxT	Dia do ano em que a vegetação atinge o máximo crescimento/vigor vegetativo
MaxV	Valor do índice de vegetação correspondente a MaxT
LengthGS	Comprimento do ciclo da cultura
BeforeMaxT	Tempo (em dias) entre OnsetT e MaxT
AfterMaxT	Tempo (em dias) entre MaxT e OffsetT
GreenUpSlope	Taxa de ganho de vigor vegetativo pela cultura agrícola
BrownDownSlope	Taxa de maturação da cultura agrícola durante a fase de senescência
TINDVIBeforeMax	Índice de vegetação acumulado entre OnsetT e MaxT
TINDVIAfterMax	Índice de vegetação acumulado entre MaxT e OffsetT
TINDVI	Índice de vegetação médio durante a fase de crescimento
Asymmetry	Assimetria do crescimento da cultura

Fonte: Adaptado de Araya et al. (2018).

A abordagem de modelagem baseada em dados multitemporais e multi-sensor do *CropPhenology* demonstrou ser eficaz na discriminação de culturas agrícolas na região estudada. O modelo apresentou uma precisão geral de 76%, com a maioria das classes de culturas obtendo precisões superiores a 80%. No entanto, algumas culturas, como batata, aveia de verão e triticales de inverno, apresentaram precisões mais baixas, abaixo de 60%. Além disso, a inclusão de métricas fenológicas melhorou o desempenho geral do modelo, enquanto a inclusão de informações topográficas não teve um impacto significativo. A Tabela 2.4 mostra uma visão geral sobre os métodos mencionados neste capítulo.

Tabela 2.4 - Tabela de comparação das ferramentas TIMESAT, Sen2Agri e *Greenbrown*.

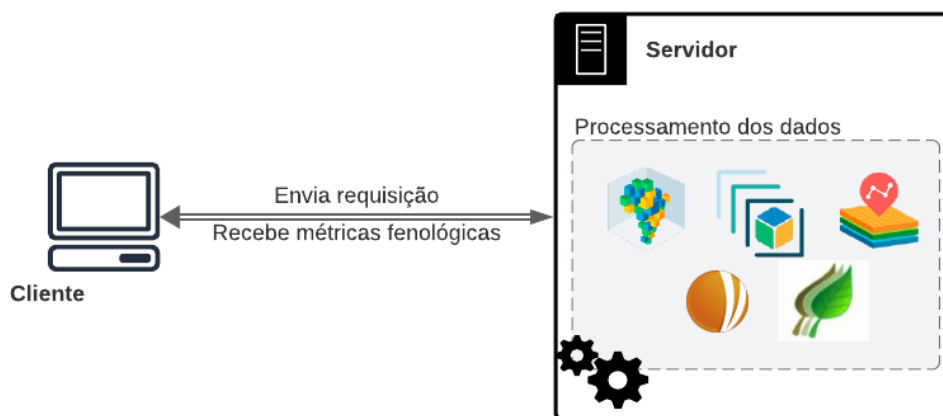
Método	Métrica	Descrição
TIMESAT (JÖNSSON; EKLUNDH, 2004)	Start t.	Data na qual a borda direita aumenta para um nível definido pelo usuário.
	End t.	Data na qual a borda esquerda diminui para um nível definido pelo usuário.
	Length	Duração da estação, data do início ao fim da estação.
	Base val.	Média dos valores mínimos esquerdo e direito.
	Peak t.	Tempo calculado para o meio da estação.
	Peak val.	Valor máximo de dados calculados pela função.
	Ampl.	Diferença entre o máximo valor e a base.
	L. deriv	Taxa de aumento do início da temporada.
	R. deriv	Taxa de decréscimo no final da temporada.
	L. integral	Integral sazonal grande.
	S. integral	Integral sazonal pequeno.
	Start value	Valor do início da estação.
	End value	Valor do fim da estação.
<i>SEN2AGRI</i> (SEN2AGRI, 2019)	t0	Data de início da estação de crescimento.
	x0	Data da taxa máxima de crescimento.
	L	Comprimento do platô de maturidade.
	t3	Data de fim da estação de crescimento.
<i>Greenbrown</i> (FORKEL et al., 2015)	SOS	Início da estação.
	EOS	Fim da estação.
	LOS	Duração da estação.
	POP	Posição do pico máximo.
	POT	Posição do valor mínimo
	MGS	Média da estação de crescimento.
	PEAK	Valor do pico de crescimento.
	trough	Valor mínimo.
	MSP	Média do valor da primavera.
	MAU	Média do valor de outono.
	RSP	Taxa de crescimento <i>greenup</i> da primavera.
RAU	Taxa de senescência de outubro.	

2.5 Recursos e estruturas computacionais

2.5.1 Arquitetura de aplicação

Na computação, existem diversos tipos de estruturas de sistemas. A arquitetura de software cliente/servidor é um modelo de arquitetura computacional na qual o servidor atua como produtor e o cliente como consumidor (UNIVERSIDADE FEDERAL DE SANTA CATARINA (UFSC), 2005). O servidor hospeda e fornece serviços de alta tecnologia com uso intensivo de computação para o cliente sob demanda. Esses serviços podem incluir acesso a aplicativos, armazenamento, compartilhamento de arquivos, acesso à impressora e/ou acesso direto ao poder de computação bruto do servidor (DEFINIRTEC, 2018). Esta arquitetura funciona quando o computador cliente envia uma solicitação de recurso ou processo ao servidor pela conexão de rede, que é então processada e entregue ao cliente. Um computador servidor pode gerenciar vários clientes simultaneamente, enquanto um cliente pode ser conectado a vários servidores ao mesmo tempo, cada um fornecendo um conjunto diferente de serviços (OLIVEIRA et al., 2019), como mostra a Figura 2.8.

Figura 2.8 - Arquitetura Cliente x Servidor.



2.5.2 Serviços web

Um serviço web é um conjunto de funções relacionadas a uma aplicação que pode ser invocada utilizando tecnologias web. As funções permitem às aplicações enviar e receber dados traduzidos em uma linguagem universal, como por exemplo os forma-

tos XML, Json, CSV e outros. Esta troca de informações se dá através de protocolos de comunicação como SOAP (*Simple Object Access*) e o REST (*Representational State Transfer*) (IBM, 2021).

O protocolo SOAP utiliza XML para enviar a mensagem e utiliza o protocolo HTTP para transportar os dados. Já o REST é um protocolo que também se baseia no protocolo HTTP e permite utilizar vários formatos para representação de dados, como JSON (um dos mais utilizados), XML, RSS, entre outros (OPENSOFTECH, 2021).

A execução destes serviços se dá através das requisições HTTP, que são mensagens enviadas pelo cliente para iniciar uma ação no servidor. Estas mensagens executam ações de acordo com os métodos HTTP (GET, POST, DELETE, etc)². Por exemplo, GET indica que um recurso deve ser obtido ou POST significa que dados serão enviados ao servidor, que recebe as informações do cliente e, caso a requisição seja válida, inicia as funções do serviço e retorna uma resposta ao solicitante (MDN WEB DOCS, 2021).

2.5.3 Integração de tecnologias computacionais

Um eventual problema que pode vir a ocorrer, se tratando de múltiplas linguagens de programação, é a integração e a comunicação entre elas em um único fluxo de serviço web. As linguagens utilizadas são R³ e Python⁴ para um serviço em Javascript, JS⁵.

Para manter a comunicação entre as diferentes tecnologias, é possível adotar algumas estratégias, como por exemplo, utilizar pacotes específicos em JS, como *rserve-js*⁶ e *python-shell*⁷, que possibilitam a execução das diferentes linguagens e retornam respostas em uma linguagem em comum, Json.

Outra opção é desenvolver serviços com as linguagens Python e R, utilizando pacotes como *Flask*⁸ e *plumber*⁹, fazendo com que a saída seja padronizada e consumida pelo serviço Web em JavaScript. Assim as diferentes linguagens de programação irão se comunicar sem problemas.

²Disponível em: <https://developer.mozilla.org/pt-BR/docs/Web/HTTP/Methods>

³Disponível em: <https://www.r-project.org/>

⁴Disponível em: <https://www.python.org/>

⁵Disponível em: <https://www.javascript.com/>

⁶Disponível em: <https://www.npmjs.com/package/rserve-js>

⁷Disponível em: <https://www.npmjs.com/package/python-shell>

⁸Disponível em: <https://flask.palletsprojects.com/en/2.1.x/>

⁹Disponível em: <https://www.rplumber.io/>

3 MATERIAIS E MÉTODOS

3.1 Arquitetura do serviço WPMS

A arquitetura do serviço WPMS é apresentada na Figura 3.1, que mostra o passo a passo desde a obtenção dos dados até a extração das métricas fenológicas. O diagrama ilustra o fluxo de etapas, começando pela obtenção dos dados e prosseguindo até a extração das métricas fenológicas, e destaca a sequência de passos envolvidos no processo, proporcionando uma visão geral do funcionamento do serviço.

Figura 3.1 - Arquitetura do serviço WPMS.



A primeira etapa do processo consiste em obter os dados de sensoriamento remoto. Esses dados foram coletados utilizando as tecnologias do INPE, especificamente os serviços disponíveis no projeto BDC: *SpatioTemporal Asset Catalog* (STAC) e *Web Time Series Service* (WTSS). O STAC é uma especificação criada para melhorar a busca de imagens de satélite, permitindo a descoberta e acesso às coleções de imagens e conjuntos de dados do BDC de forma padronizada (ZAGLIA et al., 2019). O WTSS foi desenvolvido com o propósito de oferecer à comunidade de pesquisa em sensoriamento remoto uma maneira fácil de acessar e consumir dados de imagens de satélite no formato de séries temporais (VINHAS et al., 2017).

Para o estudo, foi utilizado o cubo de dados S2-16D-2 do Sentinel-2, que contém dados de refletância de superfície com resolução espacial de 10 metros e composição temporal de 16 dias, considerando a máscara de nuvem *Scene Classification Layer*

(SCL) ¹. O período de imagens disponíveis no cubo vai de janeiro de 2018 a setembro de 2022. Para as análises, foram selecionados os períodos correspondentes às safras 2020/2021 (de setembro de 2020 a setembro de 2021) e 2021/2022 (de setembro de 2021 a setembro de 2022) para a cultura da soja, de acordo com o calendário agrícola.

A segunda etapa consiste em cinco passos de pré-processamento: normalização, máscara de nuvem, interpolação, operador zonal e suavização. O primeiro deles envolve a correção das séries temporais para padronização dos valores entre -1 e 1 para o índice NDVI usado. Além disso, é feita uma verificação do tipo de dado e de valores nulos para garantir a integridade das informações.

O segundo passo do processo de pré-processamento é a aplicação da máscara de nuvem, que no caso do cubo utilizado (S2-16D), a máscara é extraída da banda SCL, que é gerada pela composição das bandas existentes na coleção de imagens ². A Tabela 3.1 demonstra as classes para cada valor de pixel. Em seguida, são removidos os dados referentes aos pixels classificados como nuvem e sombra de nuvem (*Cloud Shadows*, *Cloud Medium Probability* e *Cloud High Probability*) para garantir a qualidade e a integridade dos dados da série temporal.

Tabela 3.1 - Máscara de nuvem Sentinel2 SCL.

Class	Pixel value
No Data	0
Saturated Or Defective	1
Dark Area Pixels	2
Cloud Shadows	3
Vegetation	4
Not Vegetated	5
Water	6
Unclassified	7
Cloud Medium Probability	8
Cloud High Probability	9
Thin Cirrus	10
Snow	11

Fonte: Main-Knorn et al. (2017).

¹Disponível em: https://brazil-data-cube.github.io/products/cube_col/S2-16D-2.html

²Disponível em: <https://brazil-data-cube.github.io/specifications/bands/SCL.html>

O terceiro passo do pré-processamento consiste na interpolação dos dados para garantir que não haja nenhum valor nulo decorrente da remoção de dados correspondentes a nuvens. Para isso, utilizamos o método de interpolação por vizinho mais próximo, que consiste em substituir os valores de pixels ausentes pelo valor do pixel mais próximo que esteja disponível. Esse processo garante que todas as séries possuam a mesma dimensão, facilitando a comparação entre elas. Além disso, a interpolação permite a redução de ruídos na série temporal, garantindo a integridade dos dados.

Logo após, é feito um filtro dos valores das séries temporais por operador zonal. Esse processo é realizado através de um método do WTSS e permite a redução da dimensionalidade dos dados e o cálculo de estatísticas mais robustas para cada zona, como a média, mediana, mínimo, máximo e desvio padrão.

O quinto e último passo de pré-processamento é a suavização dos dados, que é realizada por meio de um filtro chamado *Whittaker Smoother* (EILERS, 2003). Este filtro é uma alternativa ao popular *Savitzky-Golay* (PRESS; TEUKOLSKY, 1990), porém baseado em mínimos quadrados penalizados. A suavização é aplicada nas séries temporais com o objetivo de reduzir ruídos, permitindo uma visualização mais clara das tendências ao longo do tempo. Esse processo é importante para a análise dos dados, pois torna mais fácil identificar padrões e mudanças significativas nas séries temporais.

Para a extração das métricas fenológicas, o pacote *CropPhenology* foi utilizado pelo serviço WPMS como método para extração das métricas, devido à sua facilidade de uso e documentação clara e completa, que conta com exemplos de uso e explicação detalhada de cada função. Outro fator importante que foi levado em consideração foi o foco das métricas para a agricultura. Além de trabalhos recentes que mencionam o pacote, como o de Kyere et al. (2020), e resultados promissores de análises realizadas para este estudo.

Durante os estudos e análises que serão apresentados posteriormente, identificou-se uma limitação no pacote em relação à detecção de ciclos duplos de cultura em séries temporais anuais. Em resposta a essa limitação, foi necessária uma customização no pacote a fim de detectar e distinguir os diferentes ciclos, resultando na criação do método denominado *Double CropPhenology*.

O *Double CropPhenology* foi desenvolvido como base nos métodos mencionados na Seção 2.3, em especial o *Threshold-based, Change Detection* e o conceito de *local*

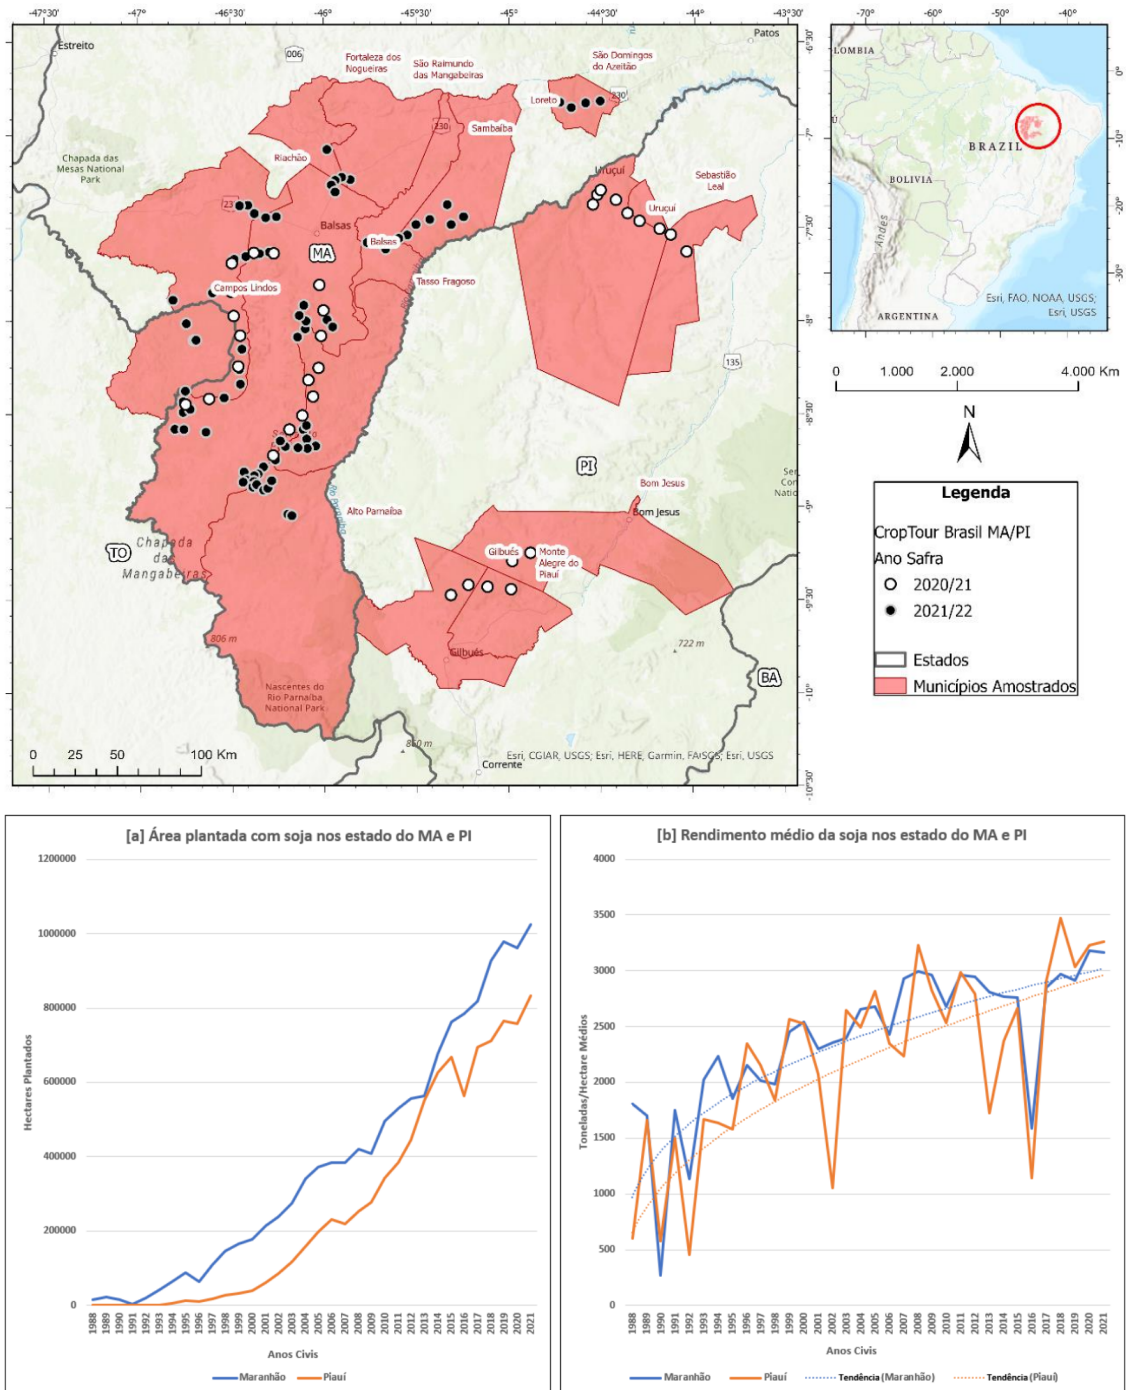
maxima and minima. Na matemática, este conceito envolve a identificação dos pontos máximos e mínimos de uma curva, considerando suas derivadas em relação às coordenadas x e y ³.

3.2 Estudo de caso: área de estudo

A área usada no estudo de caso desse trabalho compreende talhões agrícolas localizados nas regiões Sul e Norte dos estados do Maranhão (MA) e Piauí (PI), respectivamente, como mostra a Figura 3.2. Estes estados estão localizados na fronteira agrícola brasileira chamada MATOPIBA, que nos últimos anos vem sendo intensamente ocupada pelo manejo agrícola da soja (FREITAS, 2011).

³Disponível em: https://www.whitman.edu/mathematics/calculus_online/section05.01.html.

Figura 3.2 - Área de Estudo com Talhões Agrícolas nas Regiões Sul e Norte dos Estados do Maranhão (MA) e Piauí (PI) e Gráficos de Área Plantada e Rendimento Médio de Soja nos Estados.



Fonte: IBGE (2023)

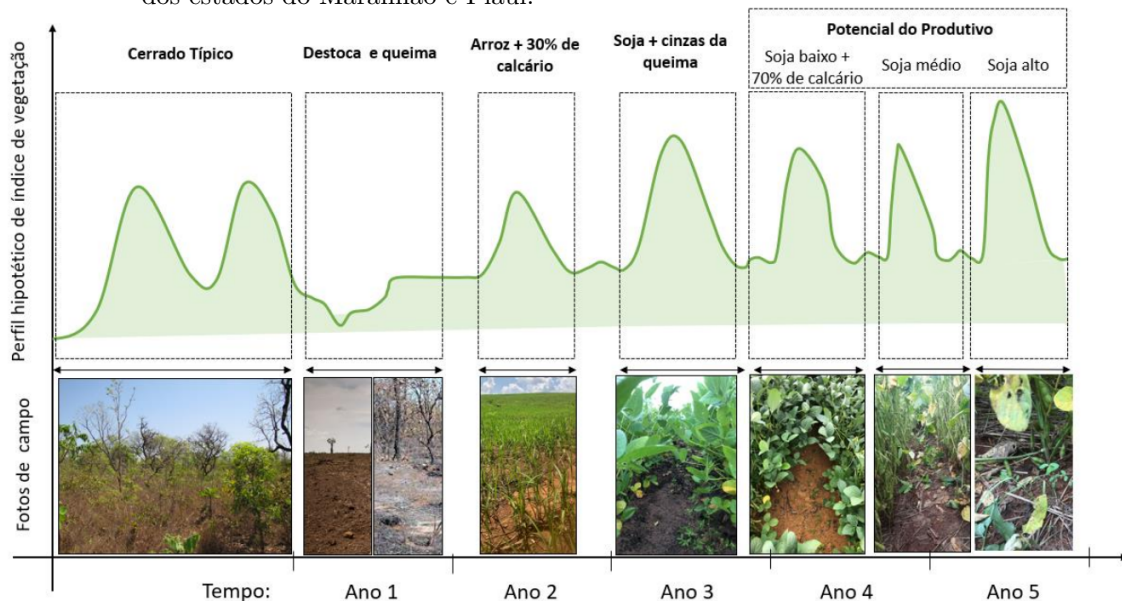
A Figura 3.2 apresenta a área de estudo, compreendendo talhões agrícolas localizados nas regiões Sul e Norte dos estados do Maranhão (MA) e Piauí (PI). Os gráficos

demonstram a área plantada e o rendimento médio de soja nos estados do MA e PI ao longo do período analisado (1998 a 2021). O eixo x representa o tempo em anos, enquanto o eixo y representa a área plantada em hectares e o rendimento médio em toneladas por hectare. Os dados destacam as variações anuais na área plantada e no rendimento médio de soja nos respectivos estados.

Nestes dois estados, a agricultura normalmente é praticada em regiões de chapadas, com maior altitude, com alto regime hídrico no início da safra da soja (meados de setembro) e baixo regime hídrico no período de colheita (meados de fevereiro). Segue abaixo a ilustração da Figura 3.3, que representa o manejo adotado para a agricultura da soja praticada nas chapadas dos estados do Maranhão (MA) e Piauí (PI).

De acordo com a Figura 3.3, a soja adquire um potencial produtivo alto, considerado acima da média estadual, no quinto ano de rotação agrícola. A Figura também mostra uma representação gráfica do perfil hipotético de índice de vegetação ao longo de uma linha do tempo anual, acompanhado por fotos de campo. As legendas ao longo do eixo x representam os diferentes manejos adotados, incluindo "Cerrado Típico", "Destoque e Queima", "Arroz + 30% de Calcário", "Soja + Cinzas da Queima", "Potencial do Produtivo com Soja Baixo + 70% de Calcário", "Soja Médio" e "Soja Alto" no quinto ano.

Figura 3.3 - Descrição visual do manejo adotado na prática da agricultura da soja nas chapadas dos estados do Maranhão e Piauí.



3.2.1 Estudo de caso: amostras coletadas em campo para validação do método de extração

Foram feitas duas campanhas de campo no Sul do Estado do MA e Norte do Estado do PI pela empresa Visiona Tecnologia Espacial⁴ para coleta de dados de produtividade potencial da soja e estádios fenológicos.

- Primeira campanha de campo: 08 a 11 de março de 2021 (33 amostras); e
- Segunda campanha de campo: 16 de janeiro a 18 de fevereiro de 2022 (78 amostras).

Durante as duas campanhas de campo, foram executados procedimentos sistemáticos, que incluíram percorrer distâncias de 10 km e coletar informações quantitativas do talhão de soja mais próximo e de fácil acesso a partir da localização atual do condutor do trabalho de campo.

Durante as atividades de campo, foram coletadas informações quantitativas, que incluíram a uniformidade do dossel do talhão, a distância entrelinhas, o número de plantas a cada 2 metros na linha, o número de sementes por planta e os estádios fenológicos, como desenvolvimento vegetativo, florescimento, enchimento de grãos, maturação, maturação (dessecado) e em colheita. A Figura 3.4 apresenta uma representação visual dos eventos observados.

Figura 3.4 - Eventos observados durante as atividades de campo.

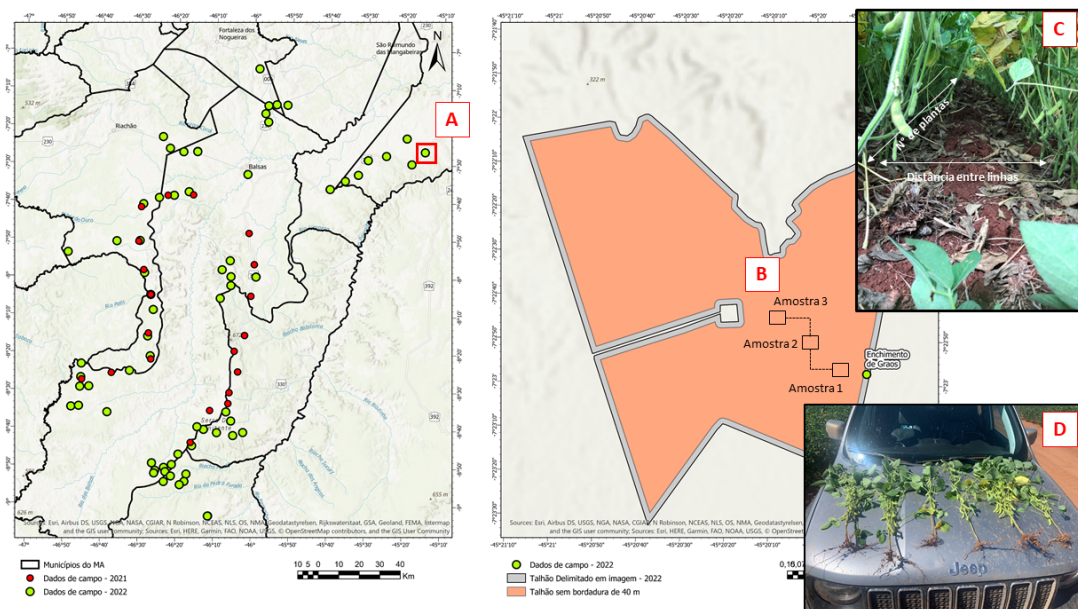


⁴Disponível em: <https://www.visionaespecial.com.br/>

Os dados de produtividade potencial foram extraídos exclusivamente dos talhões que se encontravam nas fases de maturação à senescência, seguindo um procedimento específico. Ao ingressar no talhão, foi percorrida uma distância de 30 metros para eliminar os efeitos de bordadura. Em seguida, avaliou-se a uniformidade do dossel, caminhando em forma de escada dentro do talhão. Caso o talhão não apresentasse uniformidade na altura e tivesse falhas de plantio, foram coletadas três amostras próximas, caso contrário, os levantamentos eram obtidos em intervalos maiores.

Em cada amostra, o técnico coletava o número de plantas a cada dois metros lineares e arrancava de forma sistemática duas plantas/subamostras, obedecendo um espaçamento de pelo menos 10 plantas. O procedimento foi realizado duas vezes em cada amostra. Após a extração das seis plantas, eram contadas as sementes de cada subamostra. A Figura 3.5 ilustra a coleta dos dados em campo e demonstra o método utilizado para coleta dos dados em campo: A) Dados coletados em 2021 e 2022; B) Amostragem em forma de escada; C) Coleta das informações da distância da entrelinha e número de plantas em 2 m lineares; e D) Contagem e peso das sementes por planta.

Figura 3.5 - Método utilizado para coleta dos dados em campo.



3.3 Método para validação com dados coletados em campo

Para validar as métricas fenológicas extraídas pelos métodos propostos, foram utilizados os dados de produtividade potencial e estádios fenológicos coletados em campo nas campanhas de 2020/21 e 2021/22. Na primeira análise, relacionou-se os atributos fenológicos detectados pela extração do *CropPhenology* e *Double CropPhenology* com a produtividade potencial obtida em campo para o ciclo fenológico da soja. Para isso, optou-se pelo uso da correlação de Pearson para analisar o resultado do R^2 formado entre a produtividade potencial de campo com cada um dos atributos fenológicos obtidos.

Na segunda análise, relacionou-se os atributos fenológicos *Onset* e *OffsetT* obtidos pelo *CropPhenology* e *Double CropPhenology* com os estádios fenológicos obtidos em campo, na data da coleta. Para isso, fez-se a diferença entre a data do atributo fenológico obtida em campo com a data obtida pelo atributo *OffsetT*, relacionado à colheita. Essas análises foram realizadas para avaliar a concordância entre os atributos fenológicos extraídos pelos métodos propostos e as informações coletadas em campo, fornecendo *insights* importantes sobre a validade e acurácia das métricas fenológicas.

4 RESULTADOS E DISCUSSÕES

4.1 Serviço WPMS

Com base nas análises realizadas e no objetivo proposto pelo trabalho, foi desenvolvido um serviço web para a extração de métricas fenológicas. O serviço WPMS desenvolvido tem como objetivo principal a extração de métricas fenológicas a partir de imagens de satélite. Para isso, foram criados *endpoints* que utilizam tanto o método *CropPhenology* original, quanto o método modificado.

Além disso, o serviço conta com outras funcionalidades auxiliares, como a possibilidade de extração de séries temporais, listar os cubos de dados disponíveis, realizar o download das imagens raster usadas para calcular as métricas do método *phenometrics* em formato TIFF, GRD ou GRI, e download das imagens *thumbnail* no formato PNG.

O WPMS foi desenvolvido por meio de containers, e a troca de informações é realizada no formato JSON (*JavaScript Object Notation*), o que possibilita a interoperabilidade entre as linguagens de programação utilizadas, R e Python. Essa arquitetura de desenvolvimento permite uma maior flexibilidade na escolha da linguagem de programação a ser utilizada para a integração com o serviço, além de facilitar a manutenção e escalabilidade do sistema.

O serviço WPMS disponibiliza um conjunto de operações desenvolvidas para atender às necessidades propostas pelo trabalho de extração e análise de métricas fenológicas. Essas operações são categorizadas em dois tipos principais: as principais, focadas na extração das métricas fenológicas, e as auxiliares, que oferecem funcionalidades adicionais de suporte. Essas operações estão ilustradas nas Figuras 4.1 e 4.2.

As Tabelas 4.1 e 4.2 fornecem informações complementares às Figuras 4.1 e 4.2 e apresentam uma lista dos *endpoints* principais e auxiliares, juntamente com suas respectivas descrições. A Tabela 4.1 destaca as operações principais relacionadas à extração de métricas fenológicas, enquanto a Tabela 4.2 lista as operações auxiliares, que incluem funções adicionais, como listagem de cubos de dados, extração de séries temporais e geração de imagens.

Figura 4.1 - Exemplo da documentação das principais operações disponíveis no serviço web.

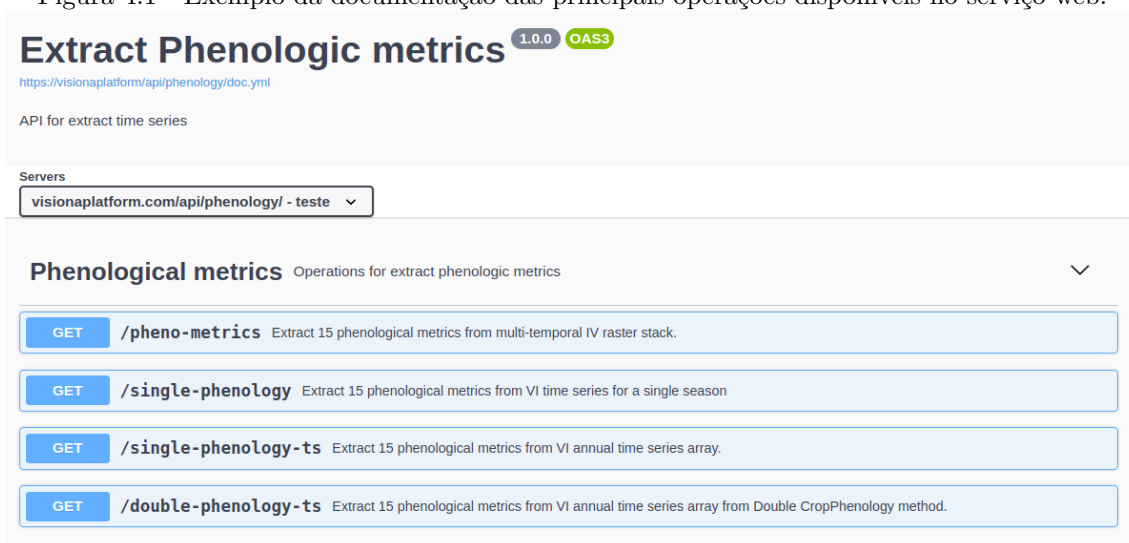


Tabela 4.1 - Tabela de *enpoints* principais relacionados à extração de métricas fenológicas.

Endpoint	Descrição
<i>pheno-metrics</i>	Esta operação é derivada do pacote <i>CropPhenology</i> e recebe como parâmetro: área de interesse, período de análise, token de acesso e nome do cubo de dados fornecidos pelo BDC. E retorna além das 15 métricas propostas pelo pacote em formatos raster <i>.tiff</i> e <i>grd</i> , as informações sobre os dados analisados.
<i>single-phenology</i>	Também é uma função derivada do <i>CropPhenology</i> que recebe os mesmos parâmetros, porém calcula as métricas através de um único ponto em uma única estação. Retorna 15 métricas propostas pelo pacote, as informações sobre a série usada e recursos do BDC. Um exemplo de sua resposta pode ser vista na Figura 4.3.
<i>single-phenology-ts</i>	Esta função é uma implementação derivada do pacote <i>CropPhenology</i> e recebe um vetor de inteiros que representa uma série temporal anual de VI. A função é projetada para calcular e retornar as 15 métricas fenológicas para a série temporal fornecida, descritos na Figura 4.4.
<i>double-phenology-ts</i>	Implementação modificada do pacote <i>CropPhenology</i> que extrai as mesmas métricas fenológicas a partir de uma série temporal anual de VI, utilizando um método adaptado.

A Tabela apresenta os *enpoints* principais do serviço, juntamente com suas descrições, que são utilizados para a extração de métricas fenológicas.

Figura 4.2 - Exemplo da documentação das operações auxiliares disponíveis no serviço web.

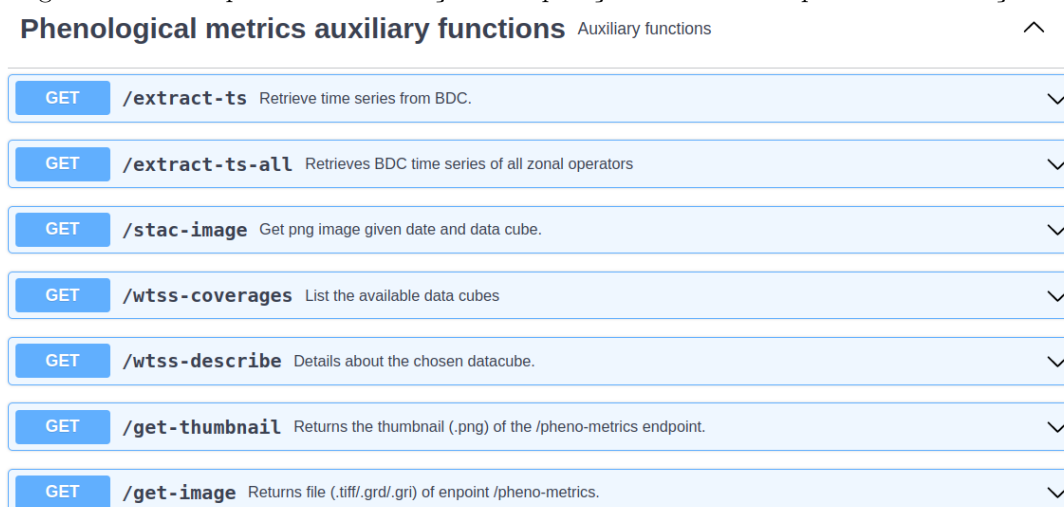


Tabela 4.2 - Tabela de *endpoints* auxiliares para funções adicionais.

Endpoint	Descrição
<i>extract-ts</i>	Responsável por extrair as séries temporais. Recebe como parâmetros um GeoJSON, o período, o cubo de dados, o token de acesso, o operador zonal e a banda desejada (NDVI ou EVI).
<i>extract-ts-all</i>	Esta função tem a mesma funcionalidade do endpoint <i>extract-ts</i> , porém realiza a extração das séries temporais para todos os operadores zonais disponíveis, eliminando a necessidade de passar o parâmetro do operador zonal.
<i>stac-image</i>	Retorna uma imagem PNG com base nos parâmetros fornecidos, como o cubo de dados, a área de interesse em formato GeoJSON, o período e token de acesso.
<i>wtss-coverages</i>	Responsável por retornar a lista de cubos de dados disponíveis BDC utilizando o serviço WTSS. Ela requer um parâmetro de token de acesso para autenticação e autorização.
<i>wtss-describe</i>	Fornece informações detalhadas sobre um cubo de dados específico. Requer o token e o nome do cubo de dados como parâmetros, e retorna informações como nome, descrição, resolução espacial e período temporal.
<i>get-thumbnail</i>	Operação auxiliar com a finalidade de retornar os thumbnails dos rasters gerados pelo <i>endpoint pheno-metrics</i> no formato <i>image/png</i> .
<i>get-image</i>	Operação auxiliar com a finalidade de retornar os rasters gerados pelo <i>endpoint pheno-metrics</i> no formato <i>image/tiff</i> ou <i>grd-file</i> .

Endpoints auxiliares do serviço e suas descrições. Essas operações complementares incluem funções como listagem de cubos de dados, extração de séries temporais e geração de imagens.

Figura 4.3 - Esquema resposta da operação *single-phenology*.

```

SinglePhenology {
  area string
  example: {"type": "Polygon", "coordinates": [[[-42.0968627929688, -19.6478313116844],[-42.0968627929688, -19.6478313116844]]]}
  datacube string
  example: S2-SEN2COR_10_160_STK-1
  period string
  example: 2019-01-01/2020-01-01
  source string
  example: https://brazildatacube.dpi.inpe.br/wtss
  service string
  example: Rwtss
  version string
  example: 0.9.2
  method string
  example: single-phenology
  time_series > [...]
  phenologic_metrics > {...}
  statistics > {...}
}

```

Figura 4.4 - Esquema resposta da operação *single-phenology-ts* e *double-phenology-ts*.

```

Schemas
├── PhenoMetrics >
├── SinglePhenology >
└── SinglePhenologyTs {
  OnsetV number
  example: 0
  OnsetT number
  example: 0
  OffsetV number
  example: 0.2009
  OffsetT number
  example: 10
  MaxV number
  example: 0.8098
  MaxT number
  example: 19
  TINDVI number
  example: 0
  TINDVIBeforeMax number
  example: 0
  TINDVIAfterMax number
  example: 0
  Assymetry number
  example: 0
  GreenUpsSlope number
  example: 0.0215
  BrownDownSlope number
  example: -0.0215
  LengthGS number
  example: 0
  BeforeMaxT number
  example: 19
  AfterMaxT number
  example: -19
}

```

A documentação foi desenvolvida utilizando o *Swagger*, uma ferramenta *open-source* utilizada para criar, documentar e consumir serviços web RESTful. Isso permitiu a geração automática de documentação para todos os *endpoints* disponíveis. Adicionalmente, o serviço já está em operação na infraestrutura da Visiona e continua a ser aprimorado e atualizado constantemente.

4.2 Desempenho de processamento

A Tabela 4.3 apresenta as especificações técnicas de hardware da máquina utilizada para o processamento de dados e informações detalhadas sobre as especificações da máquina utilizada para realizar os testes. As especificações incluem detalhes sobre o processador, memória RAM, capacidade de armazenamento e outros componentes relevantes.

Tabela 4.3 - Tabela de especificações da máquina de teste.

Especificação	Detalhes
Processador	Intel Core i7 10750H @2.60 GHz (6 núcleos)
Memória RAM	64 GB DDR4 2933 MHz ECC Registered
Armazenamento	1 x SSD 512 NVMe Gen3 x4
Rede	Rede wireless Wi-Fi 6 (802.11ax)
Placa de vídeo	GeForce RTX 2060 com 6 GB de VRAM

A Tabela 4.4 apresenta os resultados de tempo de processamento obtidos em cada *endpoint* do serviço WPMS para áreas entre 1 km² a 5 km². O tempo de execução fornece uma indicação do desempenho da máquina para cada operação realizada. Vale ressaltar que os tempos apresentados são médias obtidas a partir de dez execuções de cada *endpoint*.

Para o teste, foram utilizados os mesmos dados coletados durante as análises e estudos mencionados na Seção 3.1. O cubo de dados S2-16D-2 do Sentinel-2 e um período correspondente às safras 2020/2021 (de setembro de 2020 a setembro de 2021) e 2021/2022 (de setembro de 2021 a setembro de 2022) da cultura da soja, de acordo com o calendário agrícola.

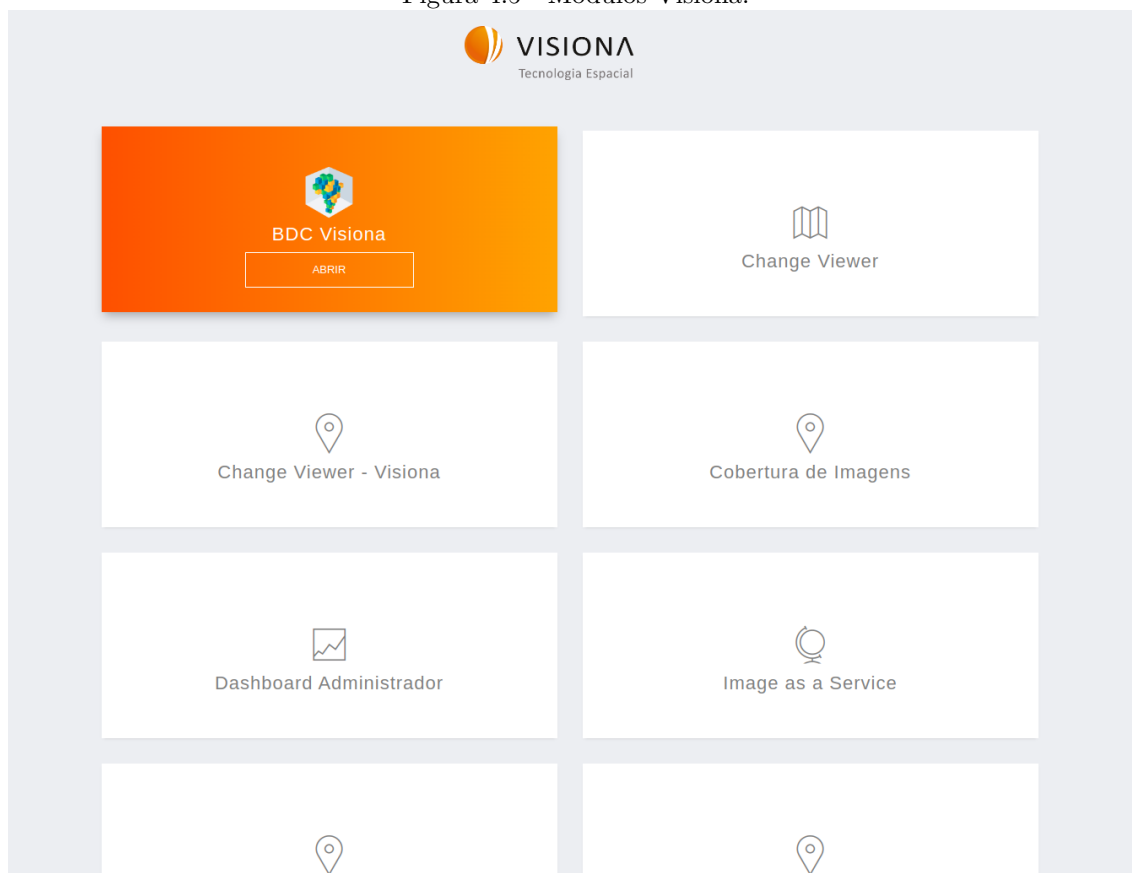
Tabela 4.4 - Tabela de desempenho de processamento por *endpoint*.

Endpoint	Tempo
<i>pheno-metrics</i>	460ms
<i>single-phenology</i>	512ms
<i>single-phenology-ts</i>	104ms
<i>double-phenology-ts</i>	17ms

4.3 Sistema web para análise e visualização dos resultados

A Visiona é uma empresa voltada para a integração de sistemas espaciais e soluções envolvendo sensoriamento remoto. Entre essas soluções, destaca-se o seu portal web, que permite a visualização de imagens de satélite gratuitas e pagas, além de oferecer uma ampla variedade de módulos especializados, como detecção de mudanças, monitoramento de queimadas e outras.

Figura 4.5 - Módulos Visiona.

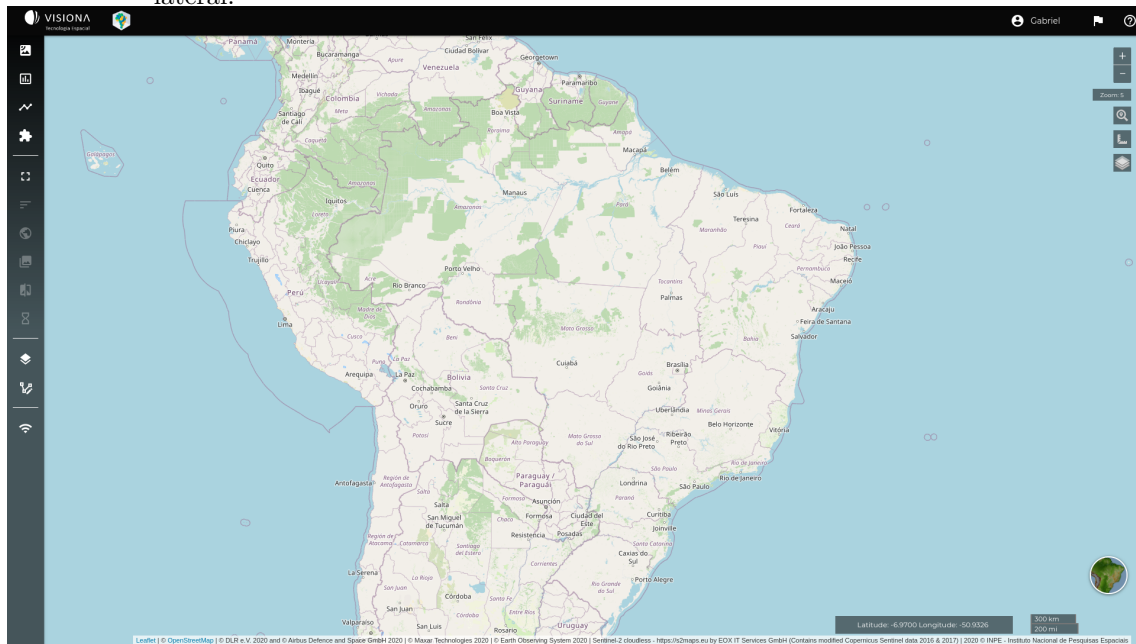


Este trabalho teve como um dos objetivos específicos desenvolver um novo módulo para o portal web da Visiona, focado na análise agrícola e na extração de métricas fenológicas a partir de imagens de satélite. Para isso, o sistema web de análise agrícola desenvolvido foi integrado ao serviço WPMS mencionado na Seção 4.1, permitindo que seus recursos e funcionalidades fossem consumidos. Dessa forma, o novo módulo tornou possível aos usuários da plataforma terem acesso a análises

mais precisas e completas do comportamento da vegetação ao longo do tempo, o que é essencial para a tomada de decisões em atividades agrícolas.

O portal possui uma página que exibe o mapa em tela cheia e um menu lateral com ícones das funcionalidades disponíveis. Ao selecionar uma funcionalidade, uma área lateral é aberta com opções de entrada do usuário, como pode ser observado na Figura 4.6.

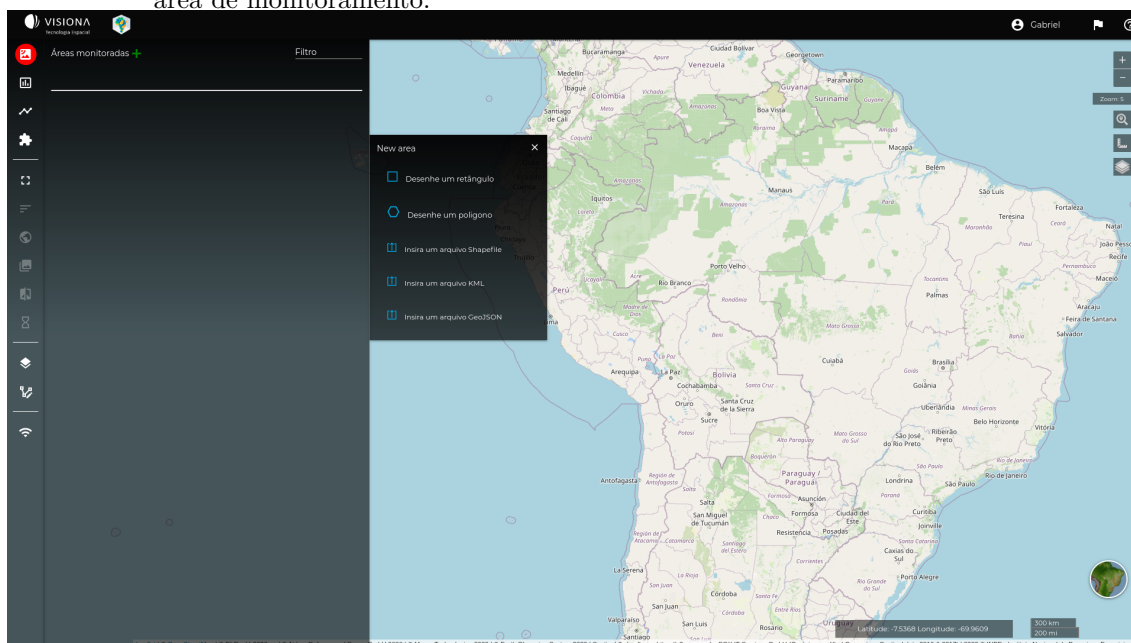
Figura 4.6 - Interface do módulo de extração de métricas fenológicas com mapa de fundo e menu lateral.



O sistema de análise agrícola desenvolvido na plataforma da Visiona pode ser dividido em três passos principais. O primeiro passo consiste na entrada da área de monitoramento desejada pelo usuário. Em seguida, é realizada a extração da série temporal de imagens de satélite correspondente à área selecionada. Por fim, é possível extrair as métricas fenológicas, as quais fornecem informações valiosas sobre o comportamento da vegetação ao longo do tempo.

Para a etapa de entrada da área de monitoramento, o usuário tem a opção de realizar o upload da área de interesse em diferentes formatos, como shapefile, geojson e kml, ou ainda desenhar o polígono diretamente na tela do sistema, como exemplificado na Figura 4.7.

Figura 4.7 - Interface web do módulo de extração de métricas fenológicas - Etapa 1: Upload de área de monitoramento.



Ao realizar o upload ou desenhar a área, é possível visualizá-la como uma camada no mapa, conforme exemplificado na Figura 4.8. Além disso, na área lateral, são exibidas as informações extraídas da área para cada talhão agrícola, como o nome e o tamanho em km^2 . Depois de selecionar o talhão que será analisado, o usuário pode mudar o *basemap* para visualizar melhor a área, como mostra a Figura 4.9.

Figura 4.8 - Interface web do módulo de extração de métricas fenológicas - Exemplo de áreas cadastradas.

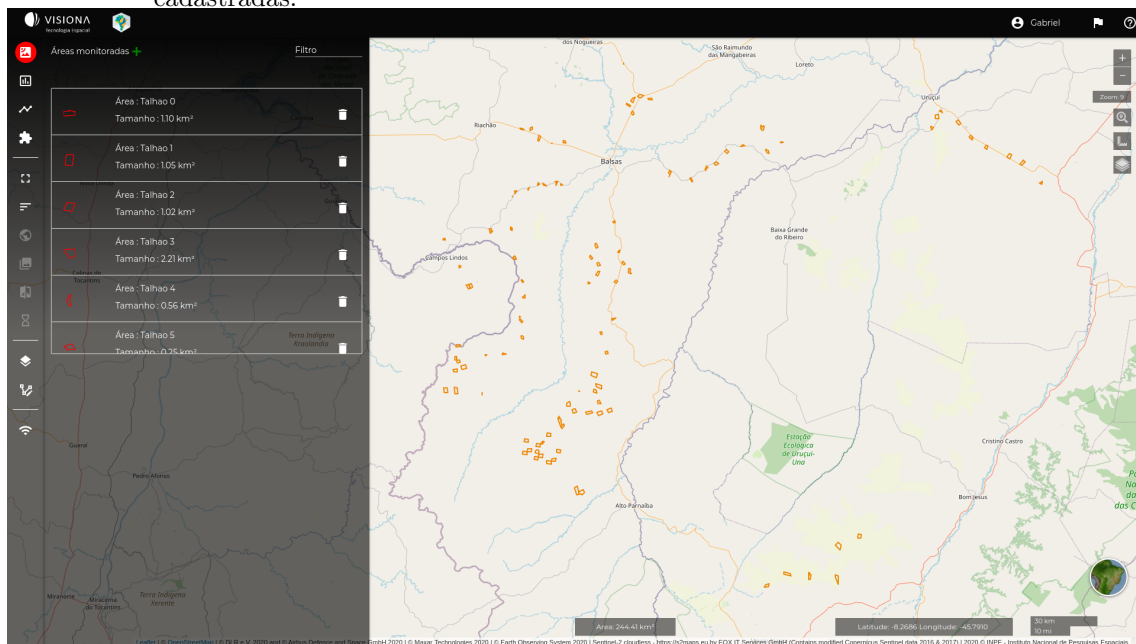
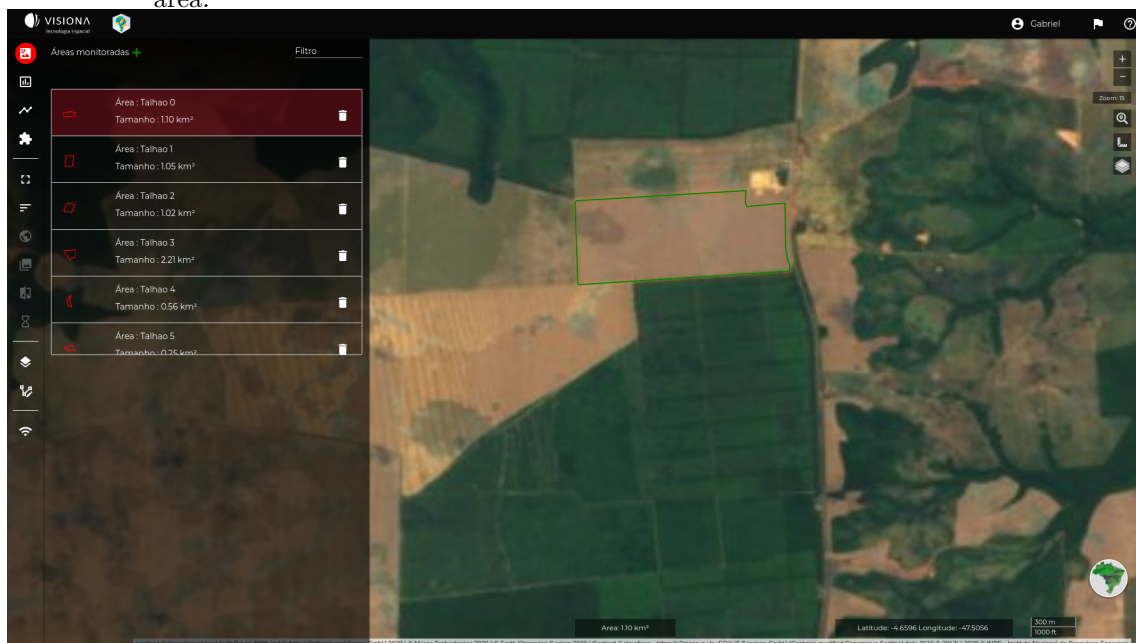


Figura 4.9 - Interface web do módulo de extração de métricas fenológicas - Exemplo de seleção de área.



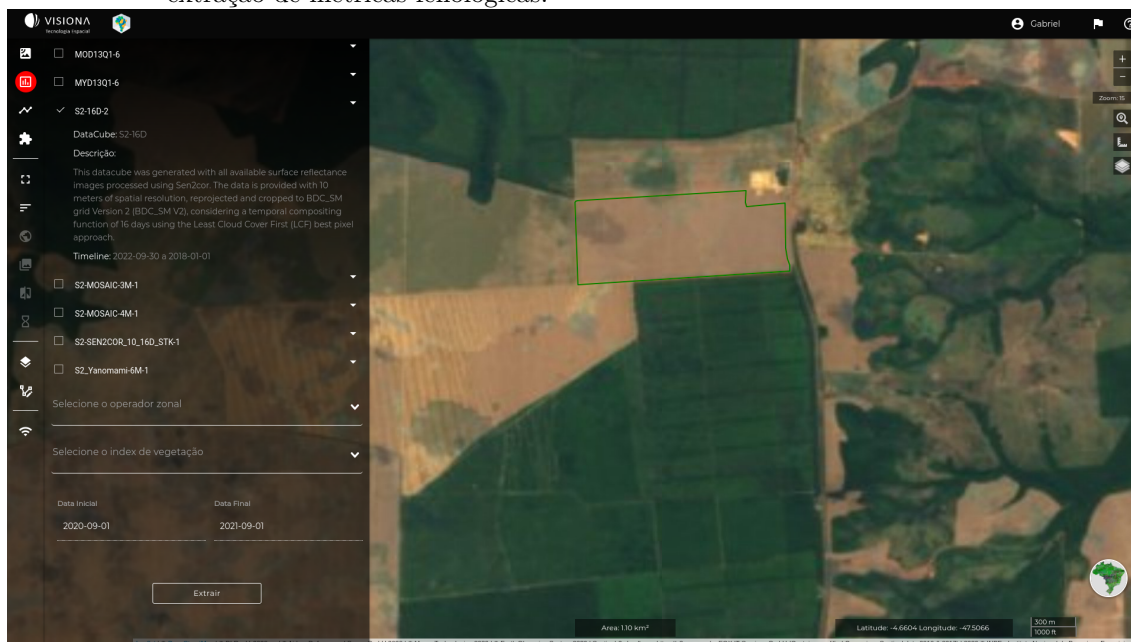
Para o segundo passo, que consiste na extração das séries temporais, o usuário deve fornecer o token de acesso ao BDC. Em seguida, são apresentados os cubos de dados disponíveis, sua descrição e o período de dados presente no cubo, como mostra a Figura 4.10.

Figura 4.10 - Extração de séries temporais de área selecionada - Interface web do módulo de extração de métricas fenológicas.



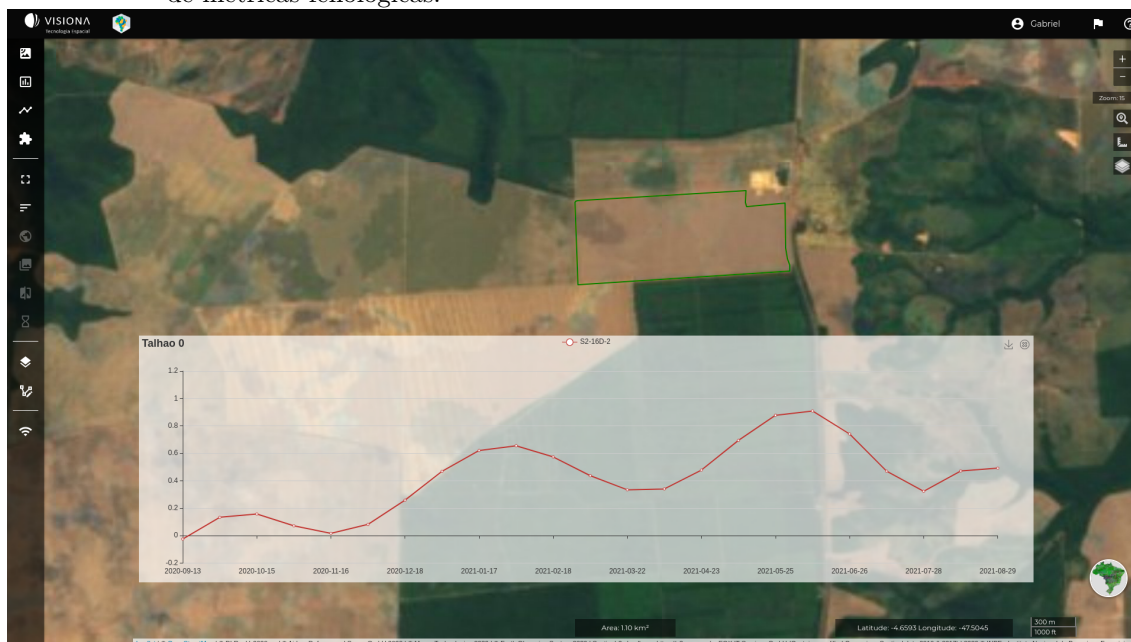
É possível selecionar mais de um cubo de dados para fazer uma análise usando múltiplos sensores. O usuário também pode escolher o operador zonal pelo qual a série temporal será agrupada, sendo as opções: média, mediana, mínimo, máximo e desvio padrão. Além disso, é possível selecionar o índice de vegetação desejado, NDVI ou EVI, e o período inicial e final da série, conforme demonstrado na Figura 4.11.

Figura 4.11 - Opção de agregação de dados zonais e índice de vegetação - Interface do módulo de extração de métricas fenológicas.



Após a seleção dos parâmetros, é feita a extração da série temporal utilizando o serviço desenvolvido. O serviço consome os dados do BDC e aplica os parâmetros selecionados para gerar a série temporal da área de interesse. O resultado da extração é apresentado em formato de um gráfico, como demonstrado na Figura 4.12, em que o eixo x representa a data, o eixo y representa o valor do índice de vegetação escolhido (NDVI ou EVI) e o nome do cubo de dados escolhido é exibido na legenda.

Figura 4.12 - Série temporal extraída de área monitorada - Interface web do módulo de extração de métricas fenológicas.



No terceiro passo, é realizada a extração das métricas fenológicas para a série temporal extraída, conforme apresentado na Figura 4.13. Nessa área, o usuário tem a opção de filtrar os atributos desejados, além de consultar a definição de cada um e ver um exemplo da métrica em uma série temporal. Além disso, é possível escolher o método desejado: *CropPhenology* ou *Double CropPhenology* e o período de análise. Os resultados dessa extração são apresentados sobre a série temporal no gráfico, adicionando os atributos fenológicos sobre a série temporal, juntamente com sua legenda, como mostram as Figuras 4.14 e 4.15.

Figura 4.13 - Extração de métricas fenológicas - Interface web do módulo de extração de métricas fenológicas.



Figura 4.14 - Resultados da extração de métricas fenológicas com o método *CropPhenology* - Interface web do módulo de extração de métricas fenológicas.

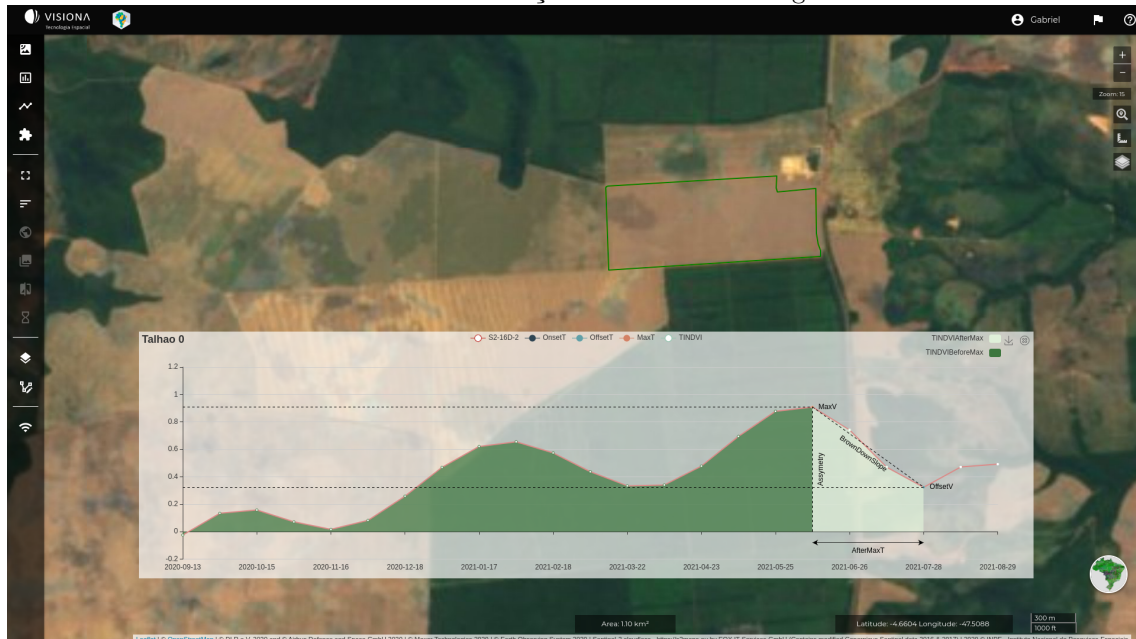
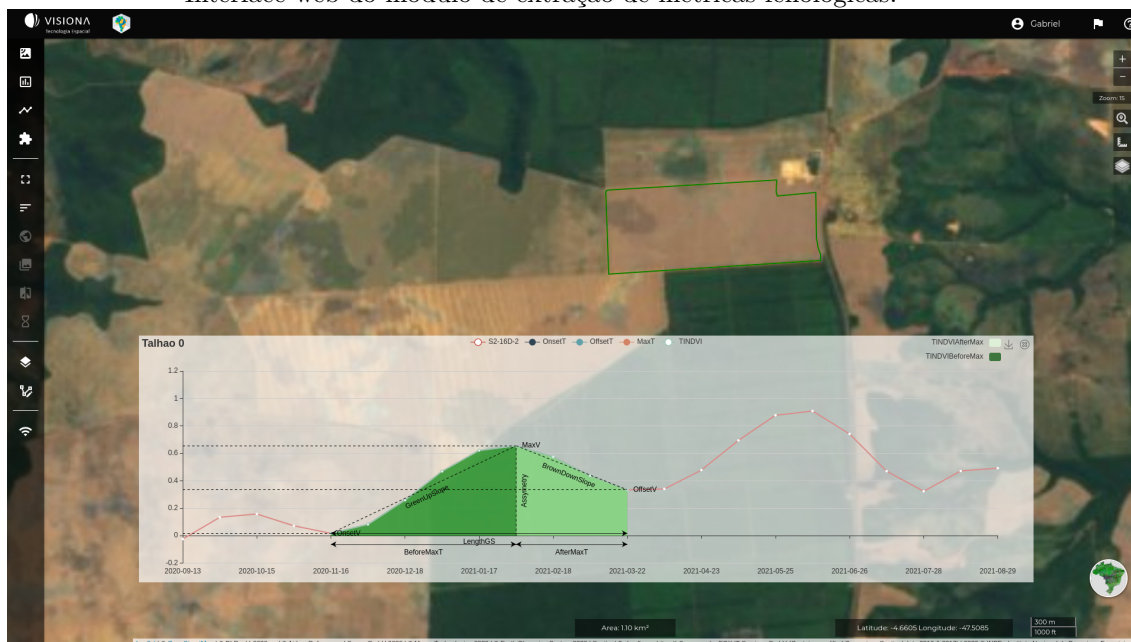


Figura 4.15 - Resultados da extração de métricas fenológicas com o método *Double CropPhenology* - Interface web do módulo de extração de métricas fenológicas.



4.4 Análise *CropPhenology*

Para uma análise mais aprofundada do método de extração de métricas fenológicas baseadas no pacote em R, o objetivo deste estudo foi avaliar a precisão das métricas extraídas pelo pacote em relação às observações realizadas no campo. As análises foram feitas a partir das áreas mencionadas na Seção 3.2.1 e ilustradas na Figura 3.5.

A Figura 4.16 e a Tabela 4.6 apresentam a análise das métricas fenológicas, conforme descrito na Tabela 2.3, em duas séries temporais de VI: NDVI e EVI, extraídas do cubo de dados Sentinel 2, com uma resolução temporal de 16 dias para um ano-safra específico (de setembro de 2020 a setembro de 2021). Essas séries foram obtidas para o primeiro talhão agrícola, e os dados foram agregados pelo operador zonal de mediana.

A Figura 4.6 mostra as séries temporais NDVI (azul) e EVI (laranja) para um talhão agrícola, juntamente com as métricas fenológicas extraídas pelo pacote. As linhas pontilhadas e os pontos indicam os atributos fenológicos, a linha vertical representa a data da visita de campo, enquanto as regiões sombreadas representam a área do ciclo detectado.

Figura 4.16 - Séries temporais NDVI e EVI e métricas fenológicas.

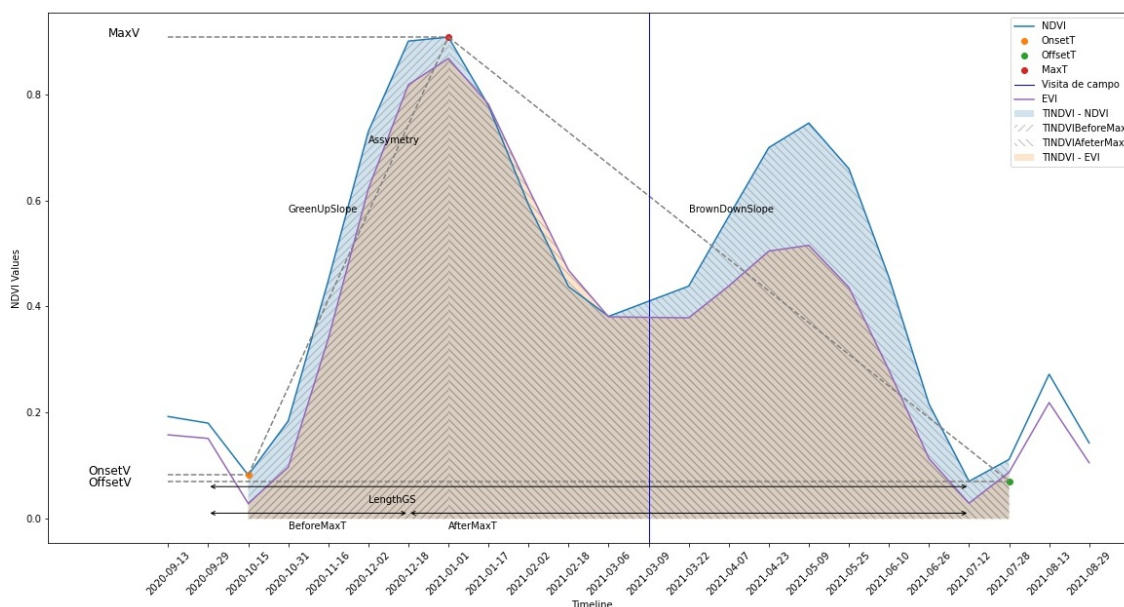


Tabela 4.5 - Métricas Fenológicas.

Métrica	NDVI	EVI
OnsetV	0.0824	0.029
OnsetT	2020-10-15	2020-10-15
OffsetV	0.0707	0.0295
OffsetT	2021-07-28	2021-07-28
MaxV	0.9074	0.8672
MaxT	2021-01-01	2021-01-01
LengthGS	286 dias	286 dias
BeforeMaxT	78 dias	78 dias
AfterMaxT	208 dias	208 dias
GreenUpSlope	0.165 NDVI/dia	0.1676 EVI/dia
BrownDownSlope	0.0644 NDVI/dia	0.0644 EVI/dia
TINDVIBeforeMax	2.7574	2.3247
TINDVIAfterMax	6.9424	5.7756
TINDVI	9.7057	8.1
Asymmetry	-4.185	-3.4509

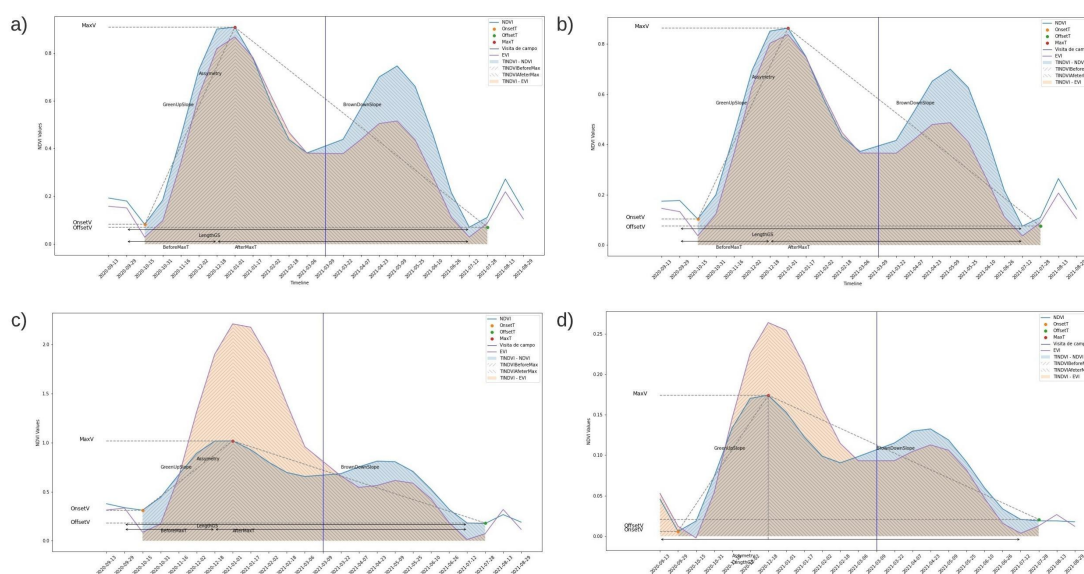
Tabela 4.6 - Tabela de métricas fenológicas para as séries temporais de NDVI e EVI.

Métrica	NDVI	EVI
OnsetV	0.0824	0.029
OnsetT	3	3
OffsetV	0.0707	0.0295
OffsetT	21	21
MaxV	0.9074	0.8672
MaxT	8	8
LengthGS	18	18
BeforeMaxT	5	5
AfterMaxT	13	13
GreenUpSlope	0.165 NDVI/dia	0.1676 EVI/dia
BrownDownSlope	0.0644 NDVI/dia	0.0644 EVI/dia
TINDVIBeforeMax	2.7574	2.3247
TINDVIAfterMax	6.9424	5.7756
TINDVI	9.7057	8.1
Asymmetry	-4.185	-3.4509

É possível observar que o método foi capaz de extrair um ciclo fenológico por meio das métricas *Onset* e *Offset*. Entretanto, não foi possível distinguir claramente um ciclo do outro, o que indica uma limitação na precisão do método em relação a essa diferenciação fenológica. Os resultados das métricas fenológicas não variaram significativamente entre os diferentes operadores zonais utilizados (média, mediana, máximo e desvio padrão), conforme mostrado na Figura 4.17.

A análise quantitativa das métricas fenológicas revelou que os valores de *Onset* e *Offset* permaneceram os mesmos, independentemente do operador zonal ou do VI utilizado, indicando uma alta robustez dessas métricas em relação à escolha do operador zonal e VI, conforme pode ser observado nas Tabelas 4.7 e 4.8. Esses resultados sugerem que a escolha do operador zonal ou do VI pode não ter um impacto significativo na estimativa das datas de início e fim do ciclo.

Figura 4.17 - Comparação das métricas fenológicas para diferentes operadores zonais.



A Figura acima traz a comparação das métricas fenológicas extraídas para as séries temporais de NDVI e EVI utilizando diferentes operadores zonais: (a) mediana, (b) média, (c) máximo e (d) desvio padrão.

Tabela 4.7 - Tabela de métricas fenológicas para diferentes operadores zonais NDVI.

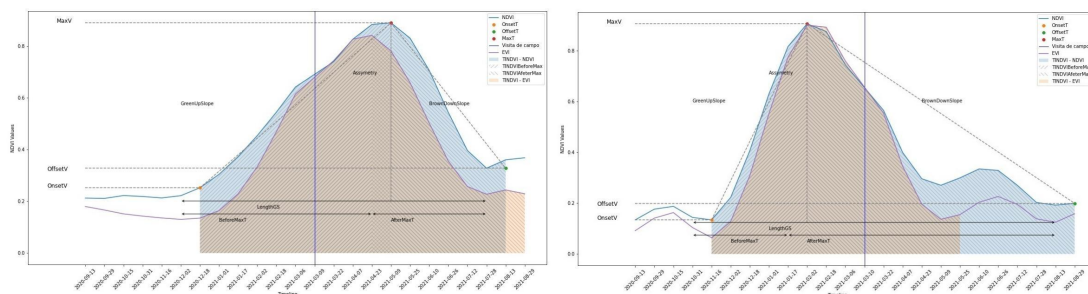
Métrica	Valores NDVI			
	Média	Mediana	Máximo	Desvio Padrão
OnsetV	0.1028	0.084	0.3114	0.006
OnsetT	3	3	3	2
OffsetV	0.0749	0.0707	0.1811	0.0208
OffsetT	21	21	21	21
MaxV	0.8626	0.9074	1.019	0.1741
MaxT	8	8	8	7
LengthGS	18	18	18	19
BeforeMaxT	5	5	5	5
AfterMaxT	13	13	13	14
GreenUpSlope	0.152	0.165	0.1415	0.0336
BrownDownSlope	0.0606	0.0644	0.0645	0.011
TINDVIBeforeMax	2.6637	2.7574	3.6871	0.4858
TINDVIAfterMax	6.6495	6.9424	9.1365	1.4695
TINDVI	9.3271	9.7057	12.8887	1.948
Asymmetry	-3.9858	-4.185	-5.4494	-0.9837

Tabela 4.8 - Tabela de métricas fenológicas para diferentes operadores zonais EVI.

Métrica	Valores EVI			
	Média	Mediana	Máximo	Desvio Padrão
OnsetV	0.0368	0.029	0.0867	0
OnsetT	3	3	3	0
OffsetV	0.0361	0.0295	0.0125	0.0036
OffsetT	21	21	21	21
MaxV	0.8372	0.8672	2.2116	0.2638
MaxT	8	8	8	7
LengthGS	18	18	18	21
BeforeMaxT	5	5	5	7
AfterMaxT	13	13	13	14
GreenUpSlope	0.1601	0.1676	0.425	0.0377
BrownDownSlope	0.0616	0.0644	0.1692	0.0186
TINDVIBeforeMax	2.3502	2.3247	5.1848	0
TINDVIAfterMax	5.5305	5.7756	11.9121	1.6222
TINDVI	7.881	8.1	17.134	1.2343
Asymmetry	-3.1803	-3.4509	-6.7273	-1.6222

Foi observado, conforme os dados do Crop Tour, que o pacote *CropPhenology* não obteve resultados precisos para métricas fenológicas em talhões com duplo ciclo de cultivo de acordo com os dados. Essa limitação pode ser explicada pelo fato de que o pacote foi desenvolvido com base em modelos que consideram apenas um ciclo de cultivo por ano.

Figura 4.18 - Séries temporais de NDVI e EVI com um ciclo anual e métricas fenológicas extraídas.



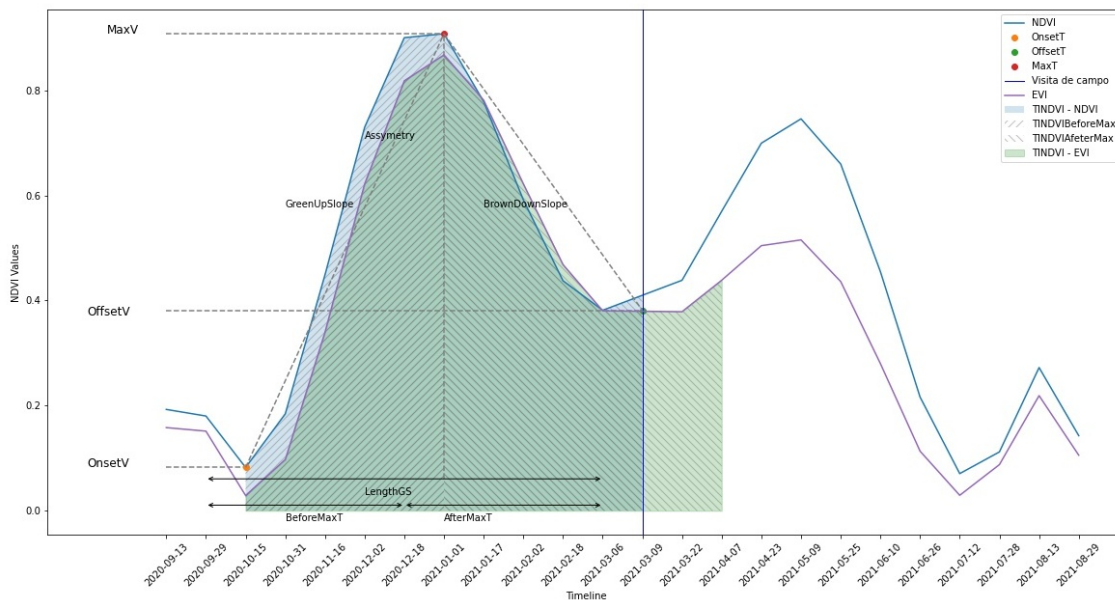
No entanto, para talhões com um único ciclo, os resultados foram satisfatórios, como pode ser observado na Figura 4.18, indicando que o pacote pode ser uma ferramenta útil para monitorar o ciclo de crescimento das plantas em determinados cenários agrícolas.

4.5 Análise *Double CropPhenology*

Considerando as limitações do pacote *CropPhenology* em talhões com duplo ciclo de cultivo, foi desenvolvida uma customização do método utilizando os mesmos atributos fenológicos do pacote. Essa customização, conforme citado na Seção 3.1, foi realizada para que o método pudesse lidar com a presença de mais de um ciclo de cultivo por ano. A customização consistiu em ajustar os modelos utilizados pelo pacote para que pudessem considerar a presença de múltiplos ciclos de cultivo.

A Figura 4.19 apresenta a mesma análise realizada na Seção anterior, porém utilizando o método modificado desenvolvido para lidar com talhões que possuem mais de um ciclo de cultivo por ano. Como pode ser observado na Tabela 4.9, a customização permitiu a detecção dos ciclos de forma independente, o que resultou em métricas fenológicas mais precisas para os talhões com duplo ciclo.

Figura 4.19 - Séries temporais NDVI e EVI e métricas fenológicas.



A Figura 4.19 demonstra as séries temporais NDVI (azul) e EVI (verde) para um talhão agrícola, juntamente com as métricas fenológicas extraídas pelo pacote. As

linhas pontilhadas e os pontos indicam os atributos fenológicos, a linha vertical representa a data da visita de campo, enquanto as regiões sombreadas representam a área do ciclo detectado.

Tabela 4.9 - Tabela de métricas fenológicas para as séries temporais de NDVI e EVI.

Métrica	NDVI	EVI
OnsetV	0.0824	0.029
OnsetT	3	3
OffsetV	0.3814	0.3787
OffsetT	12	14
MaxV	0.9074	0.8672
MaxT	8	8
LengthGS	9	11
BeforeMaxT	5	5
AfterMaxT	4	6
GreenUpSlope	0.165 NDVI/dia	0.1676 EVI/dia
BrownDownSlope	0.1315 NDVI/dia	0.0814 EVI/dia
TINDVIBeforeMax	3.4669	3.0855
TINDVIAfterMax	2.0046	2.8389
TINDVI	5.4715	5.9244
Asymmetry	1.4623	0.2466

Vale ressaltar que a customização do método proposta também mostrou resultados consistentes para os diferentes agrupamentos zonais utilizados. Isso é evidenciado na Figura 4.20, que compara as métricas fenológicas extraídas pelo método *Double CropPhenology* para as séries temporais de NDVI e EVI utilizando diferentes operadores zonais: (a) mediana, (b) média, (c) máximo e (d) desvio padrão. Além disso, os resultados das análises estão detalhados nas Tabelas 4.10 e 4.11.

Figura 4.20 - Comparação das métricas fenológicas para diferentes operadores zonais.

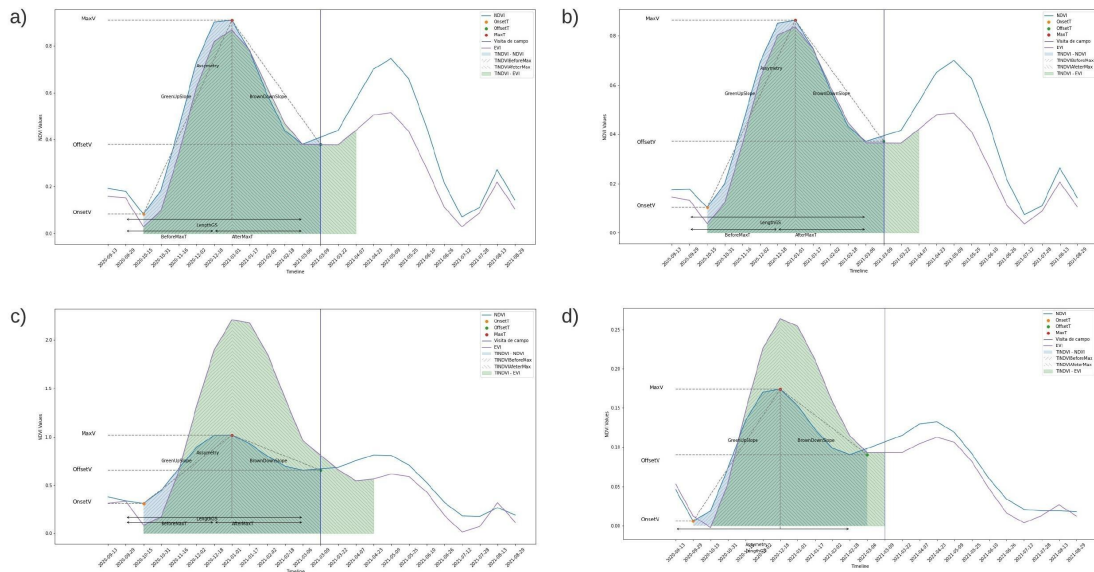


Tabela 4.10 - Tabela de métricas fenológicas para diferentes operadores zonais NDVI.

Métrica	Valores NDVI			
	Média	Mediana	Máximo	Desvio Padrão
OnsetV	0.1028	0.824	0.3114	0.006
OnsetT	3	3	3	2
OffsetV	0.3719	0.3814	0.6551	0.0906
OffsetT	12	12	12	11
MaxV	0.8626	0.9074	1.019	0.1741
MaxT	8	8	8	7
LengthGS	9	9	9	9
BeforeMaxT	5	5	5	5
AfterMaxT	4	4	4	4
GreenUpSlope	0.152	0.165	0.1415	0.0336
BrownDownSlope	0.1227	0.1315	0.091	0.0209
TINDVIBeforeMax	3.3182	3.4669	4.2837	0.6371
TINDVIAfterMax	1.9525	2.0046	2.9499	0.4377
TINDVI	5.2707	5.4715	7.2336	1.0748
Asymmetry	1.3657	1.4623	1.3338	0.1994

Tabela 4.11 - Tabela de métricas fenológicas para diferentes operadores zonais EVI.

Métrica	Valores EVI			
	Média	Mediana	Máximo	Desvio Padrão
OnsetV	0.0368	0.029	0.0867	-0.0023
OnsetT	3	3	3	3
OffsetV	0.3651	0.3787	0.544	0.0931
OffsetT	14	13	15	12
MaxV	0.8372	0.8672	2.2116	0.2638
MaxT	8	8	8	7
LengthGS	11	11	12	9
BeforeMaxT	5	5	5	4
AfterMaxT	6	6	7	5
GreenUpSlope	0.1601	0.1676	0.425	0.0665
BrownDownSlope	0.0787	0.0814	0.2382	0.0341
TINDVIBeforeMax	3.0626	3.0855	7.2506	0.7894
TINDVIAfterMax	2.7203	2.8389	7.6034	0.7502
TINDVI	5.7829	5.9244	14.854	1.5395
Asymmetry	0.3423	0.2466	-0.3528	0.0392

Essa consistência reforça a robustez da solução proposta, segundo os dados do Crop Tour, e sua capacidade de ser aplicada em diferentes cenários de monitoramento agrícola, contribuindo para a obtenção de métricas fenológicas mais precisas e confiáveis.

4.6 Análise produtividade calculada x coletadas em campo

Nesta Seção, foi realizada uma análise para avaliar a relação entre as métricas fenológicas extraídas das séries temporais NDVI e EVI usando diferentes operadores zonais e as informações de produtividade coletadas em campo. Inicialmente, utilizou-se o método de correlação de Pearson para fazer essa avaliação. Entretanto, conforme mostrado na Tabela 4.21, não foi possível estabelecer uma correlação significativa entre esses atributos de produtividade.

Posteriormente, optou-se por selecionar os atributos que possuem uma relação mais direta com a produtividade, conforme descrito no estudo de Araya et al. (2018): *GreenUpSlope*, *BrownDownSlope*, *TINDVIBeforeMax*, *TINDVIAfterMax* e *TINDVI*. No entanto, os resultados obtidos ainda não apresentaram correlação significativa entre as métricas fenológicas e a produtividade, conforme pode ser visto na Tabela 4.22.

Figura 4.21 - Relação de Pearson entre a variável Produtividade Sc/ha e as métricas fenológicas agrupadas por média como operador zonal em ordem. Os valores são apresentados em ordem crescente de correlação.

Métrica	Produtividade Sc/ha
OnsetT	-0,350508
OnsetV	-0,228757
AfterMaxT	-0,080402
OffsetT	-0,025977
GreenUpSlope	0,019147
TINDVIAfterMax	0,027271
MaxT	0,057563
OffsetV	0,084962
Assymetry	0,119475
BrownDownSlope	0,190351
LengthGS	0,267207
TINDVIBeforeMax	0,263664
TINDVI	0,295247
BeforeMaxT	0,292726
MaxV	0,23035

Essa Tabela apresenta a correlação de Pearson entre o atributo de produtividade e as métricas fenológicas relacionadas, com os valores agregados pela média.

Figura 4.22 - Correlação de Pearson entre produtividade e métricas fenológicas (Média).

Métrica	Produtividade Sc/ha
GreenUpSlope	0,019147
TINDVIAfterMax	0,027271
BrownDownSlope	0,190351
TINDVIBeforeMax	0,263664
TINDVI	0,295247

As Tabelas 4.23, 4.24, 4.25 e 4.26 apresentam os coeficientes de correlação de Pearson para diferentes operadores zonais, sendo eles, respectivamente: mínimo, máximo, mediana e desvio padrão. Os resultados indicam que não foram observadas mudanças significativas que estabeleçam uma correlação com a produtividade.

Figura 4.23 - Correlação de Pearson entre produtividade e métricas fenológicas (Mínimo).

Métrica	Produtividade Sc/ha
TINDVIBeforeMax	-0,116222
TINDVIAfterMax	-0,022047
BrownDownSlope	0,058838
TINDVI	0,110605
GreenUpSlope	0,139027

Figura 4.24 - Correlação de Pearson entre produtividade e métricas fenológicas (Máxima).

Métrica	Produtividade Sc/ha
GreenUpSlope	-0,174406
TINDVI	-0,15722
BrownDownSlope	-0,137774
TINDVIBeforeMax	-0,069783
TINDVIAfterMax	-0,051806

Figura 4.25 - Correlação de Pearson entre produtividade e métricas fenológicas (Mediana).

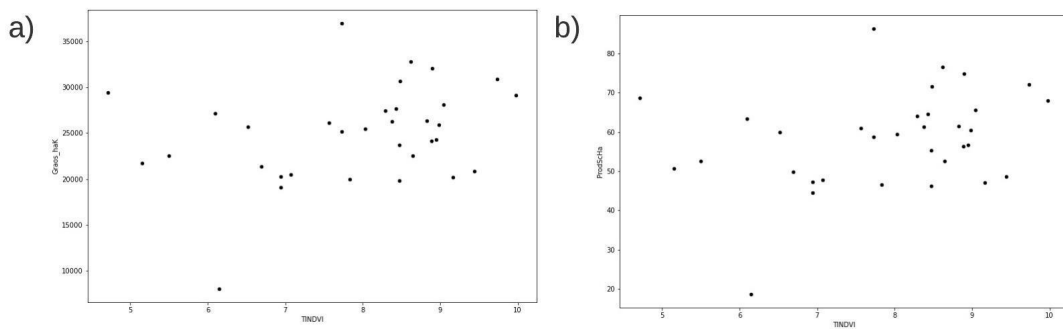
Métrica	Produtividade Sc/ha
TINDVIAfterMax	0,004411
GreenUpSlope	0,089755
TINDVI	0,154085
TINDVIBeforeMax	0,175592
BrownDownSlope	0,188489

Figura 4.26 - Correlação de Pearson entre produtividade e métricas fenológicas (Desvio Padrão).

Métrica	Produtividade Sc/ha
GreenUpSlope	-0,098034
BrownDownSlope	0,004512
TINDVIAfterMax	0,116734
TINDVIBeforeMax	0,197733
TINDVI	0,302948

Também foram realizadas análises utilizando *scatter plots*, conforme pode ser observado na Figura 4.27, que apresenta dois gráficos analisando a relação entre atributos extraídos e coletados em campo. O primeiro gráfico (a) mostra a relação entre os atributos *TINDVI* e *Graos_haK*, enquanto o segundo gráfico (b) apresenta a relação entre os atributos *TINDVI* e *ProdScHa*. Contudo, não foi possível estabelecer uma correlação significativa entre essas variáveis. Mesmo com a utilização de diferentes combinações de atributos e plotagens, nenhum padrão de comportamento foi identificado, indicando uma possível independência entre esses atributos.

Figura 4.27 - Relação entre atributos agrícolas: *TINDVI*, *Graos_haK* e *ProdScHa*.



Foram realizadas análises adicionais envolvendo atributos relacionados à produtividade, como *GreenUpSlope* e *BrownDownSlope*, além do atributo *TINDVI*. Os resultados dessas análises são ilustrados nas Figuras 4.28 e 4.29, que mostram respectivamente as relações entre os atributos *GreenUpSlope* e *Graos_haK*, *GreenUpSlope* e *ProdScHa* (Figura 4.28), e a relação entre os atributos *BrownDownSlope* e *Graos_haK*, *BrownDownSlope* e *ProdScHa* (Figura 4.29).

Figura 4.28 - Relação entre atributos agrícolas: *GreenUpSlope*, *Graos_haK* e *ProdScHa*.

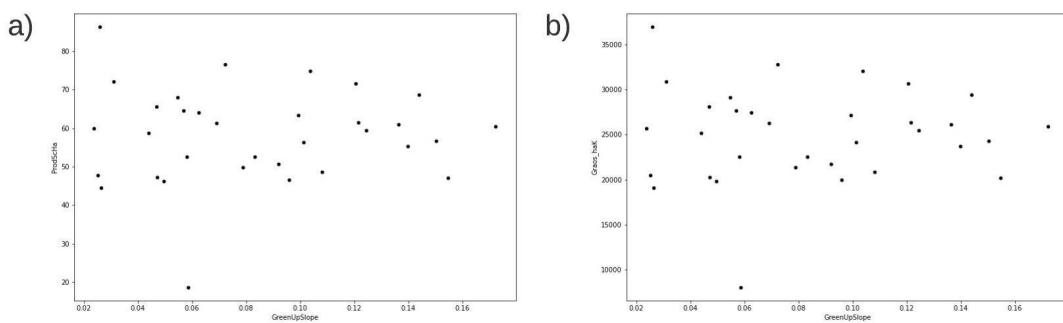
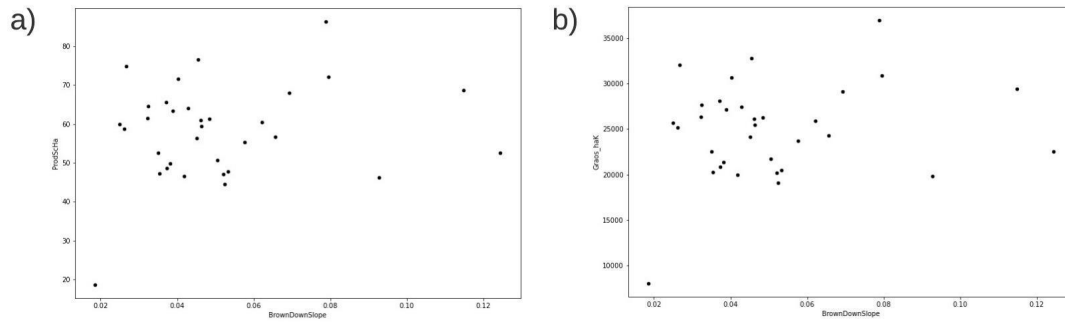


Figura 4.29 - Relação entre atributos agrícolas: BrownDownSlope, Graos_haK e ProdScHa.



Estes resultados específicos deste estudo de caso indicam que as métricas fenológicas extraídas das séries temporais NDVI e EVI não apresentaram uma relação significativa com a produtividade das culturas avaliadas. No entanto, é importante considerar que outros fatores, como condições climáticas e práticas agrícolas, também podem influenciar a produtividade e devem ser levados em conta em análises futuras.

4.7 Análise comparativa dos métodos *CropPhenology* e *Double CropPhenology*: verificação da conformidade dos ciclos fenológicos com dados de campo

Foi realizada uma análise comparativa entre os métodos *CropPhenology* e *Double CropPhenology*, com o objetivo de verificar se os ciclos fenológicos detectados estão em concordância com as informações coletadas em campo. Para isso, foi adotada uma abordagem baseada na extração de séries temporais e no cálculo das métricas fenológicas, com destaque para as métricas *Onset* e *Offset*, que indicam o início e fim do ciclo fenológico.

Inicialmente, foi empregado o *endpoint extract-all* para extrair as séries temporais de todas as 111 áreas coletadas em campo. Para a coleção de dados de satélite, foi utilizado o Sentinel-2, considerando os anos safras 2021 e 2022. Após essa etapa, foi possível criar um banco de dados de séries temporais abrangendo todas as áreas de estudo. Em seguida, foram utilizados os *endpoints single-phenology-ts* e *double-phenology-ts* para extrair informações das métricas fenológicas do banco de dados montado, que possui as colunas ID, *Onset*, *Offset*, Estádio Fenológico e Data de Coleta, conforme apresentado na Tabela 4.12. Com base nessas novas informações, foi possível verificar quantitativamente a conformidade dos ciclos fenológicos detec-

tados com a data de coleta e realizar a comparação entre os diferentes métodos. Os resultados dessas análises podem ser observados na Tabela 4.13.

Tabela 4.12 - Tabela de exemplo das métricas fenológicas extraídas pelos métodos e dados de campo.

ID	Onset	Offset	Estadio Fenológico	Data de Coleta
0	2021-11-17	2022-03-22	Maturacao	2022-02-18
1	2021-11-01	2022-03-22	Enchimento de Graos	2022-02-15
2	2021-11-01	2022-03-22	Enchimento de Graos	2022-02-15
3	2021-11-17	2022-04-07	Enchimento de Graos	2022-02-15
4	2021-11-17	2022-02-18	Em colheita	2022-02-14
7	2021-10-16	2022-02-18	Maturacao	2022-02-16

Tabela 4.13 - Resultados da análise de concordância dos ciclos fenológicos .

Metodo	Ano-safra	Conc
<i>CropPhenology</i>	2020/2021	100%
	2021/2022	100%
<i>Double CropPhenology</i>	2020/2021	72.73%
	2021/2022	87.14%

Os resultados da análise comparativa entre os métodos *CropPhenology* e *Double CropPhenology* revelaram que o método *CropPhenology* obteve uma taxa de concordância de 100% para ambos os anos-safras com as informações de campo. Por sua vez, o método *Double CropPhenology* apresentou uma taxa de concordância de 72.73% para o ano-safra 2020/2021 e 87.14% para o ano-safra 2021/2022.

O método original obteve total concordância com as informações de campo. Isso pode ser atribuído ao fato de que o período detectado pelo método, conforme evidenciado na Seção 4.4, abrange os dois ciclos presentes na série temporal. Essa abordagem mais ampla possibilita uma melhor correspondência com as datas de coleta em campo, resultando em uma maior taxa de concordância. No entanto, é importante ressaltar que uma maior taxa de concordância não necessariamente implica em um resultado mais preciso, uma vez que podem ocorrer falsos positivos. Por outro lado, o método *Double CropPhenology* não captura ambos os ciclos, como evidenciado na Seção 4.5, o que pode resultar em uma menor taxa de concordância.

4.8 Contribuições da dissertação

Esta Seção apresenta as contribuições mais significativas deste trabalho. Primeiramente, foram estudadas as principais tecnologias disponíveis para a extração das métricas fenológicas a partir de grandes volumes de imagens de sensoriamento remoto. Esse estudo incluiu a revisão da literatura existente e análise de diferentes ferramentas e softwares utilizados nesse contexto.

A principal contribuição desta dissertação é o desenvolvimento do serviço WPMS para extração de métricas fenológicas, visando tornar o processo mais eficiente e acessível, considerando a vantagem do processamento de grandes volumes de dados no lado do servidor. Um aspecto relevante é que o serviço está sendo executado na infraestrutura do BDC no INPE. Dessa forma, o WPMS representa uma importante contribuição para a área de estudos fenológicos aplicados à agricultura, uma vez que permite a extração de métricas fenológicas em larga escala de forma mais ágil e automatizada.

Outra contribuição relevante apresentada na dissertação é o desenvolvimento de um sistema web com interface gráfica que facilita a análise dos dados extraídos e permite uma melhor compreensão fenológica de talhões agrícolas selecionados. Esse sistema foi projetado com o objetivo de tornar mais fácil e acessível a interpretação dos resultados obtidos a partir da extração de métricas fenológicas. Outro aspecto relevante é a publicação um artigo *short paper* ao simpósio de Geoinformática, GEOINFO 2022, sobre o tema, que traz novas contribuições para extração de métricas fenológicas.

Além disso, a dissertação inclui um estudo de caso que analisa os métodos de extração de métricas fenológicas e permite uma avaliação completa desde a revisão da literatura até a validação empírica dos resultados coletados em campo, a partir de dados obtidos em duas campanhas (2020/2021 e 2021/2022) do Crop Tour Brasil¹ para a soja, no Maranhão e Piauí. Por fim, através desses estudos, foi possível identificar algumas limitações e áreas passíveis de aprimoramento no pacote, o que levou à realização de alterações para tentar melhorar o processo de extração.

preciso e eficiente.

¹Crop Tour Brasil é um evento anual realizado por empresas do setor agrícola brasileiro para efetuar o levantamento em campo das condições agronômicas da soja no período que compreende a primeira safra. A produtividade potencia l da soja é uma variável medida no Crop Tour, de forma objetiva, por uma metodologia única e aplicada de forma sistemática.

5 CONCLUSÕES

Com base nos resultados apresentados, pode-se afirmar que o serviço WPMS facilitou o processo de extração de métricas fenológicas considerando a vantagem processo de grandes volumes de dados e se mostrou eficiente na detecção e diferenciação de ciclos duplos para os dados do Crop Tour analisados.

Destaca-se a criação de um serviço e sistema web dedicados à extração de métricas e dados de sensoriamento remoto, proporcionando uma abordagem eficiente e escalável. Além de um *short paper* como contribuição com uma parcela do desenvolvimento do método foi submetido e aceito para o Simpósio de Geoinformática, GEOINFO em 2022.

O serviço WPMS desenvolvido demonstrou ser uma ferramenta valiosa para aplicações agrícolas, devido à sua facilidade de uso e capacidade de processar grandes volumes de dados de forma rápida e eficiente. Além disso, é importante ressaltar que o serviço já foi implementado na infraestrutura do BDC no INPE. O sistema web também cumpriu seu objetivo ao oferecer recursos de monitoramento e análise visual, contribuindo para a tomada de decisões mais informadas.

Embora não tenha sido possível estabelecer uma relação positiva entre os atributos fenológicos e a produtividade coletada em campo, os resultados obtidos forneceram informações valiosas sobre os ciclos fenológicos e sua relação com os dados coletados. Essas descobertas fornecem uma base para pesquisas futuras e o aprimoramento das técnicas de análise fenológica.

É importante ressaltar que os resultados adquiridos pelos métodos e técnicas desenvolvidos nesta dissertação são específicos para os dados de campo utilizados, que se referem à cultura da soja nas regiões Sul e Norte do Maranhão e Piauí. Esses resultados não devem ser generalizados como uma verdade absoluta para todas as culturas agrícolas e em diferentes regiões. Cada cultura e região apresentam características únicas que podem influenciar os ciclos fenológicos e as relações entre as métricas fenológicas e a produtividade. Portanto, é essencial conduzir estudos adicionais e adaptar as técnicas desenvolvidas para cada contexto específico, levando em consideração as particularidades das diferentes culturas e condições ambientais.

A adoção de índices de vegetação e métodos de processamento de imagens mais adequados para cada cultura, assim como a consideração de fatores ambientais específicos, são etapas cruciais para a obtenção de resultados mais precisos e confiáveis.

Portanto, é recomendado que futuros estudos explorem diferentes culturas agrícolas, regiões geográficas e condições climáticas, a fim de expandir o conhecimento e a aplicabilidade dessas técnicas.

Em suma, esta dissertação representa um avanço importante nas tecnologias de extração de métricas fenológicas e sua aplicação em aplicações agrícolas. No entanto, é fundamental reconhecer as limitações e a necessidade de estudos adicionais para adaptar e validar as técnicas desenvolvidas em diferentes cenários agrícolas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMI, M. **Estimativa da data de plantio da soja por meio de séries temporais de imagens MODIS**. Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2010. 8
- AMHERDT, S.; LEO, N. C. D.; BALBARANI, S.; PEREIRA, A.; CORNERO, C.; PACINO, M. C. Exploiting sentinel-1 data time-series for crop classification and harvest date detection. **International Journal of Remote Sensing**, v. 42, n. 19, p. 7313–7331, 2021. 8
- APPEL, M.; PEBESMA, E. On-demand processing of data cubes from satellite image collections with the gdalcubes library. **Data**, v. 4, n. 3, p. 92, 2019. 5
- ARAYA, S.; OSTENDORF, B.; LYLE, G.; LEWIS, M. Remote sensing derived phenological metrics to assess the spatio-temporal growth variability in cropping fields. 2017. 1, 8, 12
- _____. Cropphenology: an r package for extracting crop phenology from time series remotely sensed vegetation index imagery. **Ecological Informatics**, v. 46, p. 45–56, 2018. ISSN 1574-9541. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1574954117301644>>. 2, 13, 14, 50
- ATZBERGER, C. Advances in remote sensing of agriculture: context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949–981, 2013. 1, 11
- ATZBERGER, C.; EILERS, P. H. Evaluating the effectiveness of smoothing algorithms in the absence of ground reference measurements. **International Journal of Remote Sensing**, v. 32, n. 13, p. 3689–3709, 2011. 11
- BALI, A.; INGLADA, J.; SICRE, C. M.; TARDY, B.; DEDIEU, G. Near real-time agriculture monitoring at national scale at parcel resolution: performance assessment of the sen2-agri automated system in various cropping systems around the world. **Remote Sensing**, v. 11, n. 20, p. 2347, 2019. 12
- BERGER, K. et al. Multi-sensor spectral synergies for crop stress detection and monitoring in the optical domain: a review. **Remote Sensing of Environment**, v. 280, p. 113198, 2022. 1

BROWN, J. C.; KASTENS, J. H.; COUTINHO, A. C.; VICTORIA, D. de C.; BISHOP, C. R. Classifying multiyear agricultural land use data from Mato Grosso using time-series modis vegetation index data. **Remote Sensing of Environment**, v. 130, p. 39–50, 2013. 11

CHAVES, M. E.; ALVES, M. d. C.; SÁFADI, T.; OLIVEIRA, M. S. de; PICOLI, M. C.; SIMOES, R. E.; MATAVELI, G. A. Time-weighted dynamic time warping analysis for mapping interannual cropping practices changes in large-scale agro-industrial farms in brazilian cerrado. **Science of Remote Sensing**, v. 3, p. 100021, 2021. 1, 6, 8

DEFINIRTEC. **Arquitetura cliente / servidor**. 2018. Disponível em: <<https://definirtec.com/arquitetura-cliente-servidor/>>. Acesso em: 02 maio 2022. 16

DIAO, C.; LI, G. Near-surface and high-resolution satellite time series for detecting crop phenology. **Remote Sensing**, v. 14, n. 9, p. 1957, 2022. 1, 2

EILERS, P. H. A perfect smoother. **Analytical Chemistry**, v. 75, n. 14, p. 3631–3636, 2003. 21

FERNANDES, P. J. F.; VICENS, R. S.; FURTADO, L. Comparação de algoritmos de filtragem em séries temporais de ndvi/modis. **Revista Brasileira de Cartografia**, v. 70, n. 3, p. 867–905, 2018. 11

FERREIRA, K. R. et al. Earth observation data cubes for Brazil: requirements, methodology and products. **Remote Sensing**, v. 12, n. 24, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/24/4033>>. 5, 6, 7

FONTANA, D. C.; PINTO, D. G.; JUNGES, A. H.; BREMM, C. Using temporal ndvi/modis profiles for inferences on the crop soybean calendar. **Bragantia**, v. 74, p. 350–358, 2015. 8

FORKEL, M.; CARVALHAIS, N.; VERBESSELT, J.; MAHECHA, M. D.; NEIGH, C. S.; REICHSTEIN, M. Trend change detection in ndvi time series: Effects of inter-annual variability and methodology. **Remote Sensing**, v. 5, n. 5, p. 2113–2144, 2013. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/5/5/2113>>. 2

FORKEL, M.; MIGLIAVACCA, M.; THONICKE, K.; REICHSTEIN, M.; SCHAPHOFF, S.; WEBER, U.; CARVALHAIS, N. Codominant water control on

global interannual variability and trends in land surface phenology and greenness. **Global Change Biology**, v. 21, n. 9, p. 3414–3435, 2015. 15

FREITAS, M. A cultura da soja no Brasil: o crescimento da produção brasileira e o surgimento de uma nova fronteira agrícola. **Enciclopédia Biosfera**, v. 7, n. 12, 2011. 22

GALFORD, G. L.; MUSTARD, J. F.; MELILLO, J.; GENDRIN, A.; CERRI, C. C.; CERRI, C. E. Wavelet analysis of modis time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, v. 112, n. 2, p. 576–587, 2008. 1

GARCÍA-MOZO, H.; GALÁN, C.; JATO, V. Phenology and climate change: a long-term study in western Spain. **International Journal of Climatology**, v. 30, n. 9, p. 1455–1469, 2010. 1

GENG, L.; ZHANG, X.; HU, Y.; SONG, X.; LI, X.; LI, N. Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions. **Remote Sensing**, v. 12, n. 4, p. 736, 2020. 12

GIULIANI, G.; CHATENOUX, B.; BONO, A. D.; RODILA, D.; RICHARD, J.-P.; ALLENBACH, K.; DAO, H.; PEDUZZI, P. Building an Earth Observations data cube: lessons learned from the Swiss Data Cube (SDC) on generating Analysis Ready Data (ARD). **Big Earth Data**, v. 1, n. 1-2, p. 100–117, 2017. 5

GUSSO, A.; ARVOR, D.; DUCATI, J. R. Model for soybean production forecast based on prevailing physical conditions. **Pesquisa Agropecuária Brasileira**, v. 52, p. 95–103, 2017. 8

HADDAD, I.; GALVÃO, L. S.; BREUNIG, F. M.; DALAGNOL, R.; BOURSCHEIDT, V.; JACON, A. D. On the combined use of phenological metrics derived from different planetscope vegetation indices for classifying savannas in Brazil. **Remote Sensing Applications: Society and Environment**, v. 26, p. 100764, 2022. 7, 12

HQ, L. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, p. 457–465, 1995. 5

HUETE, A. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988. ISSN 0034-4257. Disponível em:

- <<https://www.sciencedirect.com/science/article/pii/003442578890106X>>. 5
- IBM. **Descrição geral de serviços web**. 2021. Disponível em: <<https://www.ibm.com/docs/pt/rsas/7.5.0?topic=applications-web-services-overview>>. Acesso em: 03 maio 2022. 17
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção Agrícola Municipal**. 2023. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html>>. Acesso em: 31 outubro 2023. 23
- JÖNSSON, P.; EKLUNDH, L. Timesat—a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, v. 30, n. 8, p. 833–845, 2004. 2, 11, 12, 15
- KASTENS, J. H.; BROWN, J. C.; COUTINHO, A. C.; BISHOP, C. R.; ESQUERDO, J. C. D. Soy moratorium impacts on soybean and deforestation dynamics in Mato Grosso, Brazil. **PloS One**, v. 12, n. 4, p. e0176168, 2017. 11
- KEMPENEERS, P.; SOILLE, P. Optimizing sentinel-2 image selection in a big data context. **Big Earth Data**, v. 1, n. 1-2, p. 145–158, 2017. 2
- KYERE, I.; ASTOR, T.; GRASS, R.; WACHENDORF, M. Agricultural crop discrimination in a heterogeneous low-mountain range region based on multi-temporal and multi-sensor satellite data. **Computers and Electronics in Agriculture**, v. 179, p. 105864, 2020. 13, 21
- LOBELL, D. B.; ROBERTS, M. J.; SCHLENKER, W.; BRAUN, N.; LITTLE, B. B.; REJESUS, R. M.; HAMMER, G. L. Greater sensitivity to drought accompanies maize yield increase in the us midwest. **Science**, v. 344, n. 6183, p. 516–519, 2014. 1
- MAIN-KNORN, M.; PFLUG, B.; LOUIS, J.; DEBAECKER, V.; MÜLLER-WILM, U.; GASCON, F. Sen2cor for sentinel-2. In: SPIE. **Image and Signal Processing for Remote Sensing XXIII**. [S.l.], 2017. v. 10427, p. 37–48. 20
- MATESE, A.; GENNARO, S. F. D.; SABATINO, G. **Crop phenology: how can it be used to improve agricultural management and sustainability?** [S.l.]: Academic Press, 2019. 1

MDN WEB DOCS. **Mensagens HTTP**. 2021. Disponível em: <<https://developer.mozilla.org/pt-BR/docs/Web/HTTP/Messages>>. Acesso em: 03 maio 2022. 17

NOORMETS, A. **Phenology of ecosystem processes: applications in global change research**. [S.l.]: Springer, 2009. 1

OLIVEIRA, G. B. de; ABREU, J. M. de; MACIEL, J. N.; KAPP, M. N. Implementação do módulo web baseado na arquitetura cliente-servidor para o aplicativo móvel educacional e open-source sem! o. In: SBC, 2019. **Congresso Latino-Americano de Software Livre e Tecnologias Abertas**. [S.l.], 2019. p. 135–138. 16

OPENSOFTE. **Web service: o que é, como funciona, para que serve?** 2021. Disponível em: <<https://www.opensoft.pt/web-service/>>. Acesso em: 03 maio 2022. 17

PATIL, P. et al. Sen2-agri-crop type mapping pilot study using sentinel-2 satellite imagery in india. **ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 42, n. 5, p. 649–656, 2019. 12

PETTORELLI, N. **The normalized difference vegetation index**. [S.l.: s.n.], 2013. 5

PICOLI, M. C. A. et al. Big earth observation time series analysis for monitoring brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 328–339, 2018. 8, 11

PRESS, W. H.; TEUKOLSKY, S. A. Savitzky-golay smoothing filters. **Computers in Physics**, v. 4, n. 6, p. 669–672, 1990. 21

REED, B. C.; SCHWARTZ, M. D.; XIAO, X. Remote sensing phenology. In: NOORMETS, A. (ED.). **Phenology of ecosystem processes**. [S.l.]: Springer, 2009. p. 231–246. 8

RIVAS, H.; DELBART, N.; OTTLÉ, C.; MAIGNAN, F.; VAUDOUR, E. Disaggregated proba-v data allows monitoring individual crop phenology at a higher observation frequency than sentinel-2. **International Journal of Applied Earth Observation and Geoinformation**, v. 104, p. 102569, 2021. 1

SAKAMOTO, T.; WARDLOW, B. D.; GITELSON, A. A.; VERMA, S. B.; SUYKER, A. E.; ARKEBAUER, T. J. A two-step filtering approach for detecting maize and soybean phenology with time-series modis data. **Remote Sensing of Environment**, v. 114, n. 10, p. 2146–2159, 2010. 8, 11

SANO, E. E.; BOLFE, É. L.; PARREIRAS, T. C.; BETTIOL, G. M.; VICENTE, L. E.; SANCHES, I. D. A.; VICTORIA, D. d. C. Estimating double cropping plantations in the brazilian cerrado through planetscope monthly mosaics. **Land**, v. 12, n. 3, p. 581, 2023. 8

SEN2AGRI. **Sentinel-2 for Agriculture**. 2019. Disponível em: <<http://www.esa-sen2agri.org/>>. Acesso em: 02 set. 2022. 2, 15

SIMÕES, R.; CAMARA, G.; QUEIROZ, G.; SOUZA, F.; ANDRADE, P.; SANTOS, L.; CARVALHO, A.; FERREIRA, K. **Satellite image time series analysis for big earth observation data**. **Remote Sens.** [S.l.]: MDPI, 2021. 1, 6

SIQUEIRA, A. et al. Ceos analysis ready data for land—an overview on the current and future work. In: IEEE. **IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium**. [S.l.], 2019. p. 5536–5537. 5

SONG, X.-P.; LI, H.; POTAPOV, P.; HANSEN, M. C. Annual 30 m soybean yield mapping in Brazil using long-term satellite observations, climate data and machine learning. **Agricultural and Forest Meteorology**, v. 326, p. 109186, 2022. 8

STEPANOV, A.; DUBROVIN, K.; SOROKIN, A.; ASEEVA, T. Predicting soybean yield at the regional scale using remote sensing and climatic data. **Remote Sensing**, v. 12, n. 12, p. 1936, 2020. 8

UDROIU, C.; NICOLA, L.; CARA, C.; SAVINAUD, M.; BELLEMANS, N.; MALCORPS, P.; BONTEMPS, S.; DEFOURNY, P. **Sen2Agri-Software-User-Manual-3.0.pdf**. ESA - Benjamin KOETZ, may 2019. Disponível em: <<http://www.esa-sen2agri.org/wp-content/uploads/Sen2Agri-Software-User-Manual-3.0.pdf>>. 12

UNIVERSIDADE FEDERAL DE SANTA CATARINA (UFSC). **Redes de computadores**. 2005. Disponível em: <<http://www.inf.ufsc.br/~j.barreto/cca/internet/redesde.htm>>. Acesso em: 02 maio 2022. 16

- VINHAS, L.; QUEIROZ, G. R. de; FERREIRA, K. R.; CAMARA, G. Web services for big earth observation data. **Revista Brasileira de Cartografia**, v. 69, n. 5, 2017. [2](#), [19](#)
- WANG, J.; HUANG, J.; YANG, P.; HUANG, W.; WANG, X. Assessment of rice phenology using timesat in combination with moderate resolution imaging spectroradiometer time-series data. **International Journal of Applied Earth Observation and Geoinformation**, v. 47, p. 75–84, 2016. [11](#)
- WHITE, M. A.; BEURS, K. M. de; DIDAN, K.; INOUYE, D. W.; RICHARDSON, A. D.; JENSEN, O. P.; O'KEEFE, J.; ZHANG, G.; NEMANI, R. R. Intercomparison, interpretation, and assessment of spring phenology in North America estimated from remote sensing for 1982–2006. **Global Change Biology**, v. 15, n. 10, p. 2335–2359, 2009. [1](#)
- WOŹNIAK, E. et al. Multi-temporal phenological indices derived from time series sentinel-1 images to country-wide crop classification. **International Journal of Applied Earth Observation and Geoinformation**, v. 107, p. 102683, 2022. [8](#)
- YANG, Y.; TAO, B.; LIANG, L.; HUANG, Y.; MATOCHA, C.; LEE, C. D.; SAMA, M.; MASRI, B. E.; REN, W. Detecting recent crop phenology dynamics in corn and soybean cropping systems of kentucky. **Remote Sensing**, v. 13, n. 9, p. 1615, 2021. [8](#)
- ZAGLIA, M. C.; VINHAS, L.; QUEIROZ, G. R. de; SIMÕES, R. E. O. Catalogação de metadados do cubo de dados do Brasil com o spatiotemporal asset catalog. In: **SIMPÓSIO BRASILEIRO DE GEOINFORMÁTICA (GEOINFO)**. [S.l.: s.n.], 2019. p. 280–285. [19](#)
- ZENG, L.; WARDLOW, B. D.; XIANG, D.; HU, S.; LI, D. A review of vegetation phenological metrics extraction using time-series, multispectral satellite data. **Remote Sensing of Environment**, v. 237, p. 111511, 2020. [1](#), [2](#), [6](#), [7](#), [9](#)
- ZHANG, M.; ABRAHAO, G.; COHN, A.; CAMPOLO, J.; THOMPSON, S. A modis-based scalable remote sensing method to estimate sowing and harvest dates of soybean crops in Mato Grosso, Brazil. **Heliyon**, v. 7, n. 7, p. e07436, 2021. [7](#), [8](#), [9](#), [10](#), [11](#)
- ZHANG, Q.; KONG, D.; SHI, P.; SINGH, V. P.; SUN, P. Vegetation phenology on the qinghai-tibetan plateau and its response to climate change (1982–2013). **Agricultural and Forest Meteorology**, v. 248, p. 408–417, 2018. ISSN

0168-1923. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168192317303532>>. 2

ZHAO, H.; YANG, Z.; DI, L.; PEI, Z. Evaluation of temporal resolution effect in remote sensing based crop phenology detection studies. In: SPRINGER.

Computer and Computing Technologies in Agriculture V: 5th IFIP TC 5/SIG 5.1 Conference, CCTA 2011, Beijing, China, October 29-31, 2011, Proceedings, Part II 5. [S.l.], 2012. p. 135–150. 1

ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. S. Automated mapping of soybean and corn using phenology. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151–164, 2016. 8, 10, 11

APÊNDICE A

Tabela A.1 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/ha	Condição Lavoura	Estim. Visual	Prod. Potencial
2022-02-18	Maturacao	50.0	16.0	173.33	158.4	29813.33	29813.33	5. Excelente	70sc/ha	69.56
2022-02-15	Enchimento de Graos	50.0	25.0	266.67	123.8	33377.78	33377.78	5. Excelente	75sc/ha	77.88
2022-02-15	Enchimento de Graos	50.0	28.0	266.67	99.8	27111.11	27111.11	5. Excelente	70sc/ha	63.26
2022-02-15	Enchimento de Graos	50.0	21.0	223.33	142.0	32420.56	32420.56	5. Excelente	70sc/ha	75.65
2022-02-15	Enchimento de Graos	50.0	27.0	256.67	82.2	21688.33	21688.33	4. Boa	65sc/ha	50.61
2022-02-15	Maturacao	45.0	21.0	248.15	87.6	21919.75	21919.75	3. Media	55sc/ha	51.15
2022-02-15	Maturado (dessecado)	50.0	21.0	216.67	123.2	25711.11	25711.11	4. Boa	60sc/ha	59.99
2022-02-15	Maturacao	50.0	21.0	223.33	83.4	20695.56	20695.56	4. Boa	60sc/ha	48.29
2022-02-15	Em colheita	45.0	22.0	259.26	93.2	24111.11	24111.11	4. Boa	65sc/ha	56.26
2022-02-15	Enchimento de Graos	50.0	32.0	310.0	73.6	22991.67	22991.67	4. Boa	60sc/ha	53.65
2022-02-15	Em colheita	50.0	22.0	256.67	83.0	21859.44	21859.44	3. Media	55sc/ha	51.01
2022-02-10	Enchimento de Graos	50.0	29.0	266.67	87.0	23688.89	23688.89	4. Boa	55sc/ha	55.27
2022-02-10	Maturacao	45.0	16.0	281.48	113.8	33496.3	33496.3	3. Media	50sc/ha	78.16
2022-02-10	Enchimento de Graos	50.0	26.0	200.0	111.0	21233.33	21233.33	4. Boa	55sc/ha	49.54
2022-02-10	Enchimento de Graos	50.0	24.0	230.0	95.8	23843.33	23843.33	4. Boa	55sc/ha	55.63
2022-02-10	Maturado (dessecado)	50.0	22.0	216.67	109.8	22641.67	22641.67	4. Boa	60sc/ha	52.83

Tabela A.2 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/hak	Condição Lavoura	Estim. Visual	Prod. Potencial
2022-02-10	Desenv. Vegetativo	50.0	28.0	233.33	103.8	23411.11	23411.11	4. Boa	60sc/ha	54.63
2022-02-11	Desenv. Vegetativo	50.0	20.0	216.67	106.8	23002.78	23002.78	3. Media	50sc/ha	53.67
2022-02-11	Maturado (dessecado)	50.0	23.0	243.33	103.0	25833.89	25833.89	4. Boa	60sc/ha	60.28
2022-02-11	Maturado (dessecado)	50.0	23.0	243.33	103.0	25833.89	25833.89	4. Boa	60sc/ha	60.28
2022-02-12	Maturacao	50.0	22.0	266.67	91.4	23866.67	23866.67	4. Boa	55sc/ha	55.69
2022-02-17	Maturacao	50.0	14.0	133.33	134.4	19222.22	19222.22	3. Media	50sc/ha	44.85
2022-02-12	Maturado (dessecado)	50.0	23.0	250.0	89.2	22250.0	22250.0	4. Boa	65sc/ha	51.92
2022-02-17	Maturacao	50.0	22.0	226.67	92.4	20248.89	20248.89	4. Boa	60sc/ha	47.25
2022-02-12	Maturado (dessecado)	50.0	28.0	296.67	75.0	21360.0	21360.0	4. Boa	60sc/ha	49.84
2022-02-12	Maturado (dessecado)	50.0	33.0	323.33	69.6	22848.89	22848.89	4. Boa	55sc/ha	53.31
2022-02-17	Maturacao	50.0	26.0	280.0	86.6	24966.67	24966.67	4. Boa	65sc/ha	58.26
2022-02-17	Maturacao	50.0	26.0	263.33	111.2	28659.44	28659.44	4. Boa	65sc/ha	66.87
2022-02-17	Maturado (dessecado)	50.0	26.0	213.33	92.2	17884.44	17884.44	4. Boa	55sc/ha	41.73
2022-02-17	Maturado (dessecado)	50.0	28.0	246.67	84.8	20514.44	20514.44	4. Boa	60sc/ha	47.87
2022-02-17	Maturado (dessecado)	50.0	33.0	316.67	67.8	20477.78	20477.78	3. Media	45sc/ha	47.78
2022-02-17	Maturacao	50.0	22.0	223.33	95.4	20174.44	20174.44	4. Boa	55sc/ha	47.07

Tabela A.3 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/hak	Condição Lavoura	Estim. Visual	Prod. Potencial
2022-02-17	Maturacao	50.0	26.0	280.0	52.4	15446.67	15446.67	3. Media	50sc/ha	36.04
2022-02-12	Maturado (dessecado)	50.0	23.0	216.67	102.0	22172.22	22172.22	4. Boa	65sc/ha	51.74
2022-02-12	Enchimento de Graos	50.0	27.0	256.67	99.8	25025.0	25025.0	4. Boa	65sc/ha	58.39
2022-02-12	Maturado (dessecado)	50.0	36.0	323.33	69.6	22956.67	22956.67	4. Boa	60sc/ha	53.57
2022-02-17	Em colheita	50.0	32.0	293.33	69.2	19897.78	19897.78	4. Boa	55sc/ha	46.43
2022-02-17	Em colheita	50.0	31.0	260.0	44.4	13476.67	13476.67	2. Ruim	40sc/ha	31.45
2022-02-12	Maturado (dessecado)	45.0	28.0	333.33	78.6	26166.67	26166.67	4. Boa	60sc/ha	61.06
2022-02-12	Em colheita	45.0	28.0	329.63	73.6	24722.22	24722.22	4. Boa	65sc/ha	57.69
2022-01-18	Maturacao	50.0	27.0	340.0	61.4	20286.67	20286.67	4. Boa	50sc/ha	47.34
2022-02-16	Maturado (dessecado)	50.0	30.0	330.0	74.0	23210.0	23210.0	4. Boa	50sc/ha	54.16
2022-02-16	Maturacao	50.0	28.0	260.0	105.2	26086.67	26086.67	4. Boa	65sc/ha	60.87
2022-02-16	Maturado (dessecado)	45.0	24.0	255.56	73.8	19422.22	19422.22	3. Media	45sc/ha	45.32
2022-02-16	Maturado (dessecado)	45.0	25.0	296.3	93.8	28049.38	28049.38	4. Boa	65sc/ha	65.45
2022-02-16	Em colheita	50.0	27.0	250.0	87.4	22000.0	22000.0	4. Boa	60sc/ha	51.33
2022-02-16	Maturacao	55.0	30.0	272.73	78.4	20954.55	20954.55	4. Boa	60sc/ha	48.89
2022-02-16	Maturacao	50.0	24.0	260.0	77.2	21840.0	21840.0	4. Boa	55sc/ha	50.96

Tabela A.4 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/hak	Condição Lavoura	Estim. Visual	Prod. Potencial
2022-02-16	Maturacao	45.0	26.0	296.3	94.0	27209.88	27209.88	4. Boa	60sc/ha	63.49
2022-02-16	Maturacao	45.0	22.0	262.96	63.4	16566.67	16566.67	3. Média	45sc/ha	38.66
2022-02-16	Maturacao	50.0	32.0	303.33	86.4	30333.33	30333.33	4. Boa	65sc/ha	70.78
2022-01-16	Maturacao	50.0	36.0	370.0	75.0	27688.33	27688.33	4. Boa	60sc/ha	64.61
2022-01-16	Enchimento de Graos	50.0	24.0	250.0	91.2	24500.0	24500.0	4. Boa	65sc/ha	57.17
2022-01-16	Maturacao	50.0	40.0	456.67	61.0	29150.56	29150.56	5. Excelente	60sc/ha	68.02
2022-01-16	Maturacao	50.0	46.0	480.0	53.0	25680.0	25680.0	3. Média	55sc/ha	59.92
2022-02-16	Maturacao	50.0	22.0	236.67	78.0	19209.44	19209.44	4. Boa	50sc/ha	44.82
2022-02-16	Maturacao	50.0	20.0	223.33	89.6	19169.44	19169.44	5. Excelente	65sc/ha	44.73
2022-02-16	Maturado (dessecado)	50.0	20.0	200.0	69.2	15333.33	15333.33	4. Boa	55sc/ha	35.78
2022-01-16	Enchimento de Graos	50.0	23.0	303.33	81.4	24772.22	24772.22	5. Excelente	65sc/ha	57.8
2022-01-16	Enchimento de Graos	50.0	25.0	273.33	108.8	28973.33	28973.33	5. Excelente	65sc/ha	67.6
2022-01-16	Enchimento de Graos	50.0	33.0	326.67	78.8	24663.33	24663.33	4. Boa	60sc/ha	57.55
2022-01-28	Maturacao	50.0	25.0	266.67	72.8	20088.89	20088.89	5. Excelente	65sc/ha	46.87
2022-01-28	Maturado (dessecado)	50.0	40.0	396.67	38.4	16660.0	16660.0	3. Média	50sc/ha	38.87
2022-02-14	Enchimento de Graos	50.0	26.0	270.0	82.0	23220.0	23220.0	5. Excelente	70sc/ha	54.18

Tabela A.5 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/hak	Condição Lavoura	Estim. Visual	Prod. Potencial
2022-02-14	Maturado (dessecado)	50.0	26.0	276.67	75.8	20703.89	20703.89	4. Boa	60sc/ha	48.31
2022-02-14	Maturacao	50.0	17.0	176.67	119.8	21023.33	21023.33	3. Media	50sc/ha	49.05
2022-02-14	Maturado (dessecado)	50.0	31.0	286.67	76.2	20974.44	20974.44	4. Boa	65sc/ha	48.94
2022-02-14	Maturado (dessecado)	50.0	27.0	260.0	74.0	18850.0	18850.0	3. Media	55sc/ha	43.98
2022-02-14	Enchimento de Graos	50.0	24.0	250.0	97.8	23750.0	23750.0	4. Boa	60sc/ha	55.42
2022-02-14	Enchimento de Graos	50.0	15.0	176.67	143.4	24615.56	24615.56	3. Media	50sc/ha	57.44
2022-02-14	Maturacao	50.0	27.0	266.67	81.4	20844.44	20844.44	4. Boa	60sc/ha	48.64
2022-02-14	Enchimento de Graos	50.0	32.0	266.67	76.8	18711.11	18711.11	3. Media	55sc/ha	43.66
2022-02-14	Em colheita	50.0	27.0	253.33	97.2	23855.56	23855.56	4. Boa	65sc/ha	55.66
2022-02-14	Em colheita	50.0	27.0	253.33	97.2	23855.56	23855.56	4. Boa	65sc/ha	55.66
2022-02-14	Enchimento de Graos	50.0	24.0	250.0	97.8	23750.0	23750.0	4. Boa	60sc/ha	55.42
2022-02-12	Enchimento de Graos	50.0	25.0	226.67	104.2	24291.11	24291.11	4. Boa	65sc/ha	56.68
2022-02-12	Enchimento de Graos	50.0	25.0	226.67	104.2	24291.11	24291.11	4. Boa	65sc/ha	56.68
2022-02-16	Maturacao	50.0	24.0	223.33	91.0	20025.56	20025.56	4. Boa	55sc/ha	46.73
2021-03-09	Maturacao	50.0	34.0	373.33	65.6	24266.67	24266.67	4. Boa	60sc/ha	56.62
2021-03-09	Maturacao	50.0	16.0	170.0	168.0	29155.0	29155.0	4. Boa	55sc/ha	68.03

Tabela A.6 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/hak	Condição Lavoura	Estim. Visual	Prod. Potencial
2021-03-09	Maturacao	50.0	20.0	223.33	98.0	20174.44	20174.44	4. Boa	50sc/ha	47.07
2021-03-09	Maturacao	50.0	29.0	320.0	85.6	25866.67	25866.67	4. Boa	65sc/ha	60.36
2021-03-09	Enchimento de Graos	50.0	19.0	183.33	127.0	23711.11	23711.11	4. Boa	60sc/ha	55.33
2021-03-09	Maturacao	50.0	18.0	213.33	110.0	24106.67	24106.67	4. Boa	50sc/ha	56.25
2021-03-09	Maturacao	50.0	20.0	223.33	97.2	20807.22	20807.22	4. Boa	50sc/ha	48.55
2021-03-09	Maturacao	50.0	17.0	190.0	118.8	22515.0	22515.0	2. Ruim	40sc/ha	52.54
2021-03-08	Maturacao	50.0	25.0	263.33	114.4	32038.89	32038.89	4. Boa	60sc/ha	74.76
2021-03-08	Maturacao	50.0	20.0	186.67	114.2	19942.22	19942.22	4. Boa	55sc/ha	46.53
2021-03-08	Maturacao	50.0	23.0	256.67	29.4	7999.44	7999.44	2. Ruim	40sc/ha	18.67
2021-03-08	Maturacao	50.0	11.0	150.0	219.6	30850.0	30850.0	4. Boa	45sc/ha	71.98
2021-03-08	Enchimento de Graos	50.0	32.0	286.67	94.2	25656.67	25656.67	4. Boa	55sc/ha	59.87
2021-03-08	Maturacao	50.0	12.0	126.67	188.4	21385.56	21385.56	3. Media	55sc/ha	49.9
2021-03-08	Maturacao	50.0	13.0	146.67	139.8	20508.89	20508.89	3. Media	45sc/ha	47.85
2021-03-08	Maturacao	50.0	28.0	306.67	104.2	30666.67	30666.67	4. Boa	60sc/ha	71.56
2021-03-08	Maturado (dessecado)	50.0	23.0	216.67	89.2	19788.89	19788.89	4. Boa	55sc/ha	46.17
2021-03-09	Maturacao	50.0	9.0	193.33	131.8	26325.56	26325.56	4. Boa	60sc/ha	61.43

Tabela A.7 - Tabela de dados de campo: Cultura de Soja - Regiões Sul e Norte do MA e PI.

Data	Estádios Fenológicos	Espaçamento	Plantas/2m	Plantas/ha	Grãos/planta	Grãos*k/ha	Graos/hak	Condição Lavoura	Estim. Visual	Prod. Potencial
2021-03-10	Maturacao	40.0	28.0	358.33	77.0	25143.06	25143.06	4. Boa	60sc/ha	58.67
2021-03-10	Maturacao	50.0	32.0	350.0	65.8	22516.67	22516.67	4. Boa	60sc/ha	52.54
2021-03-10	Maturacao	50.0	23.0	236.67	116.0	26230.56	26230.56	4. Boa	60sc/ha	61.2
2021-03-10	Enchimento de Graos	50.0	20.0	180.0	179.2	32760.0	32760.0	5. Excelente	65sc/ha	76.44
2021-03-10	Maturacao	50.0	19.0	180.0	122.6	20250.0	20250.0	4. Boa	55sc/ha	47.25
2021-03-10	Enchimento de Graos	50.0	21.0	220.0	91.8	21706.67	21706.67	4. Boa	60sc/ha	50.65
2021-03-11	Maturacao	50.0	28.0	240.0	131.6	27680.0	27680.0	4. Boa	60sc/ha	64.59
2021-03-11	Enchimento de Graos	50.0	13.0	103.33	305.2	36976.11	36976.11	5. Excelente	70sc/ha	86.28
2021-03-11	Maturacao	50.0	27.0	250.0	107.4	29416.67	29416.67	4. Boa	60sc/ha	68.64
2021-03-11	Maturacao	50.0	26.0	266.67	104.4	27422.22	27422.22	4. Boa	60sc/ha	63.99
2021-03-11	Maturacao	50.0	22.0	216.67	120.8	25494.44	25494.44	4. Boa	60sc/ha	59.49
2021-03-11	Enchimento de Graos	50.0	15.0	176.67	145.8	28119.44	28119.44	4. Boa	60sc/ha	65.61
2021-03-11	Maturado (dessecado)	50.0	21.0	210.0	90.6	19110.0	19110.0	3. Media	45sc/ha	44.59
2021-03-11	Maturacao	50.0	20.0	166.67	153.8	26138.89	26138.89	4. Boa	50sc/ha	60.99
2021-03-11	Enchimento de Graos	50.0	20.0	250.0	95.8	27166.67	27166.67	4. Boa	55sc/ha	63.39