



UNIVERSIDADE
ESTADUAL DO
MARANHÃO



UNIVERSIDADE ESTADUAL DO MARANHÃO - UEMA
CAMPUS BALSAS
PROGRAMA DE PÓS-GRADUAÇÃO AGRICULTURA E AMBIENTE -
PPGAA

AIRTON ANDRADE DA SILVA

ANÁLISE DA FENOLOGIA E PRODUTIVIDADE DA SOJA UTILIZANDO
ÍNDICES DE VEGETAÇÃO EM DIFERENTES RESOLUÇÕES ESPACIAIS

Balsas - MA

2024

AIRTON ANDRADE DA SILVA

**ANÁLISE DA FENOLOGIA E PRODUTIVIDADE DA SOJA UTILIZANDO
ÍNDICES DE VEGETAÇÃO EM DIFERENTES RESOLUÇÕES ESPACIAIS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Agricultura e Ambiente PPGAA/UEMA como parte dos requisitos para obtenção do título de Mestre em Agricultura e Ambiente.

Orientador: Francisco Charles dos Santos Silva
Eng. Agr. Prof. Dr. em Fitotecnia.

Balsas - MA

2024

Silva, Airton Andrade da
Análise da fenologia e produtividade da soja utilizando índices
de vegetação em diferentes resoluções espaciais / Airton Andrade da Silva.
– São Luis, MA, 2024.
86 f

Dissertação (Mestrado em Agricultura e Ambiente) – Universidade
Estadual do Maranhão, 2024.

Orientador: Prof. Dr. Francisco Charles dos Santos Silva.

1.Fisiologia Vegetal. 2.Sensoriamento Remoto. 3.Sensores
Orbitais.
4.Estatística Multivariada. 5.Aprendizado de Máquinas. I.Título.

AIRTON ANDRADE DA SILVA

**ANÁLISE DA FENOLOGIA E PRODUTIVIDADE DA SOJA UTILIZANDO
ÍNDICES DE VEGETAÇÃO EM DIFERENTES RESOLUÇÕES ESPACIAIS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Agricultura e Ambiente PPGAA/UEMA como parte dos requisitos para obtenção do título de Mestre em Agricultura e Ambiente.

Orientador: Francisco Charles dos Santos Silva
Eng. Agr. Prof. Dr. em Fitotecnia.

Aprovada em 29/01/2024

BANCA EXAMINADORA

Documento assinado digitalmente
 FRANCISCO CHARLES DOS SANTOS SILVA
Data: 27/03/2024 16:02:46-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Francisco Charles dos Santos Silva
(Orientador)

Documento assinado digitalmente
 JOSE FRANCISCO DA CRUZ NETO
Data: 27/03/2024 21:33:46-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. José Francisco da Cruz Neto
(Coorientador)

Documento assinado digitalmente
 LEANDRA MATOS BARROZO
Data: 28/03/2024 08:52:15-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Leandra Matos Barrozo
(Convidado para a banca)

AGRADECIMENTOS

Quero agradecer inicialmente ao meu Orientador, Francisco Charles, pelo comprometimento, auxílio, paciência e companheirismo durante toda minha trajetória no Programa.

Agradeço a minha família e amigos que me acompanharam nessa jornada de aprendizado e desafios.

Agradeço aos meus colegas de Curso pelo apoio nas disciplinas e na escrita da dissertação.

Agradeço também a Coordenação de Aperfeiçoamento de Pessoa de Nível Superior (CAPES) pela concessão da Bolsa de Auxílio, o que possibilitou minha total dedicação ao desenvolvimento da minha Pesquisa.

Enfim, obrigado a todos que direta e indiretamente fizeram parte dessa etapa importante da minha vida profissional e pessoal.

LISTA DE ABREVIACÃO

IV -	Índice de Vegetação
IVs -	Índices de Vegetação
NDVI -	Índice de Vegetação por Diferenciação Normalizada
NDWI -	Índice de Água por Diferenciação Normalizada
SAVI	Índice de Vegetação Ajustado ao Solo
VARI -	Índice de Resistência Atmosférica Visível
IV GREEN -	Índices de resistência atmosférica Verde Visível
GLI -	Índice Folha Verde
IAF	Índice da Área Foliar
VANT	Veículos Não Tripuláveis
RGB	Red, Green e Blue
NIR	Infravermelho
TEA	Taxa de Erro Aparente

LISTA DE IMAGENS

CAPÍTULO 1

Fig 1. Localização da área de estudo.....	19
Fig 2. Dados de Temperatura, Precipitação total e Nebulosidade durante os meses de execução do experimento em Balsas no ano 2022 [19].	20
Fig 3. Aspecto morfológico da soja nos diferentes estádios fenológicos em que foram obtidas informações espectrais pelos satélites Sentinel-2 e Amazônia-1.	23
Fig 4. Metodologia da pesquisa.	28
Fig 5. Comportamento dos índices de vegetação (IVs) NDVI, NDWI, SAVI (tipo NIR), e VARI, GLI e IV GREEN (tipo RGB) nos satélites Sentinel-2 e Amazônia-1.	29
Fig 6. Porcentagem de classificações corretas dos estádios fenológicos da soja, por meio dos índices de vegetação NIR (NDVI, NDWI e SAVI) e RGB (IV GREEN, GLI e VARI) dos satélites Sentinel-2 e Amazônia-1, via análise discriminante.....	32
Fig 7. Box Plot para o índice vegetativo VARI, do satélite Sentinel-2, e para o índice de área foliar (IAF) da soja.....	36

CAPÍTULO 2

Fig 1. Localização da área de estudo.....	45
Fig 2. Dados de Temperatura, Precipitação total e Nebulosidade durante os meses de execução do experimento em Balsas no ano 2022 [21].	46
Fig 3. Aspecto morfológico da soja nos diferentes estádios fenológicos em que foram obtidas informações espectrais pelos satélites Sentinel-2 e Amazônia-1.	49
Fig 4. Esquema de funcionamento do algoritmo de Floresta Aleatória (Random Forest).	51
Fig 5. Fluxograma da metodologia da presente pesquisa.	52
Fig 6. Boxplot representando a dispersão dos dados dos índices de vegetação para os sistemas-sensores Sentinel-2 (A) e Amazonia-1 (B).	53
Fig 7. Classificação correta dos IV para a estimativa dos estádios fenológicos da soja para os diferentes sistemas-sensores.	54
Fig 8. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs NIR para o sistema-sensor Sentinel-2.....	56

Fig 9. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs RGB para o sistema-sensor Sentinel-2.....	56
Fig 10. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs NIR para o sistema-sensor Amazonia-1.	57
Fig 11. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs RGB para o sistema-sensor Amazonia-1.	57
Fig 12. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta em conjunto dos grupos de IVs para o sistema-sensor Sentinel-2.....	58
Fig 13. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta em conjunto dos grupos de IVs para o sistema-sensor Amazonia-1.	58

CAPÍTULO 3

Fig 1. Localização da área experimental.	67
Fig 2. Temperatura, precipitação total, nebulosidade e insolação durante os meses de execução do experimento, em Balsas, MA no ano de 2022 [16].	67
Fig 3. Aspecto morfológico da soja nos diferentes estádios fenológicos, dos quais foram obtidas as informações espectrais pelos satélites Sentinel-2 e Amazônia-1.....	70
Fig 4. Resumo da metodologia da pesquisa.....	75
Fig 5. Redes de correlações envolvendo a produtividade de grãos de soja e índices de vegetação (IV) obtidos com sistemas-sensores do Sentinel-2 e Amazonia-1.	77

LISTA DE TABELAS

CAPÍTULO 1

Tabela 1. Estádios Fenológicos da soja [20].	21
Tabela 2. Especificações técnicas do sensor MSI embarcado no satélite Sentinel-2 e do sensor WFI embarcado no satélite Amazônia-2.	22
Tabela 3. Índices de vegetação	24
Tabela 4. Comportamento dos índices ao longo do ciclo da soja para os produtos Sentinel-2.	25
Tabela 5. Comportamento dos índices ao longo do ciclo da soja para os produtos Amazonia-1	26
Tabela 6. Taxa de Erro Aparente (TEA) (%) dos índices para os sistemas-sensor Sentine-2 e Amazonia-1, obtidos via Funções Discriminante de Anderson.	30

CAPÍTULO 2

Tabela 1. Estádios Fenológicos da soja [22].	47
Tabela 2. Especificações técnicas do sensor MSI embarcado no satélite Sentinel-2 e do sensor WFI embarcado no satélite Amazônia-2.	48
Tabela 3. Índices de vegetação.	50
Tabela 4. Análise de variância para os dados do Sentinel-2.....	52

CAPÍTULO 3

Tabela 1. Estádios fenológicos da soja [17]	68
Tabela 2. Especificações técnicas do sensor MSI embarcado no satélite Sentinel-2 e do sensor WFI embarcado no satélite Amazônia-2.	69
Tabela 3. Índices de vegetação.	71
Tabela 4. Comportamento dos índices de vegetação (IVs) ao longo do ciclo da soja, para os produtos Sentinel-2	72
Tabela 5. Comportamento dos índices de vegetação (IVs) ao longo do ciclo da soja, para os produtos Amazonia-1.....	73
Tabela 6. Resumo da análise de variância dos dados dos sistemas-sensores estudados. .	76
Tabela 7. Análise de trilha sob multicolinearidade para o sistema-sensor Amazonia-1..	79
Tabela 8. Análise de trilha sob multicolinearidade para o satélite Sentinel-2.....	79

SUMÁRIO

1 INTRODUÇÃO	10
2 OBJETIVOS	14
2.1 Objetivo geral.....	14
2.2 Objetivo específicos	14
CAPÍTULO 1. ÍNDICES DE VEGETAÇÃO COM DIFERENTES RESOLUÇÕES ESPACIAIS NO RECONHECIMENTO DA FENOLOGIA DA SOJA.....	16
Introdução	17
Metodologia.....	18
Local da pesquisa.....	18
Condução do experimento	20
Processamento das imagens.....	23
Estatística	27
Resumo da metodologia	28
Resultados e Discussão	28
Conclusões	36
CAPÍTULO 2. RECONHECIMENTO DOS ESTÁDIOS FENOLÓGICOS DA SOJA A PARTIR DE ÍNDICES DE VEGETAÇÃO ANALISADOS VIA <i>RANDOM FOREST</i>...	42
Introdução	43
Metodologia.....	44
Caracterização do local de estudo	44
Condução do experimento	46
Processamento das imagens.....	49
Estatística	50
Resumo da metodologia	51
Resultados e Discussão	52
Conclusões	59
CAPÍTULO 3. ESTIMATIVA DA PRODUTIVIDADE DA SOJA A PARTIR DE ÍNDICES DE VEGETAÇÃO POR MEIO DE DIFERENTES SISTEMAS-SENSORES	63
Introdução	64
Metodologia.....	66
Caracterização do local de estudo	66

Condução do experimento	68
Processamento das imagens.....	70
Estatística	73
Resumo da metodologia	74
Resultados e Discussão	75
Conclusões	85

RESUMO

O objetivo foi identificar Índices de Vegetação com potencial para identificar os estádios fenológicos e estimar a produtividade da soja a partir de diferentes sistemas-sensores. A pesquisa foi realizada, em Balsas, MA, Brasil, numa área de pivô central com avaliações semanais da fenologia e do Índice de Área Foliar (IAF). Foram coletados dados espectrais da área de estudo a partir dos sensores MSI e WFI embarcados nos satélites Sentinel-2 e Amazônia-1, respectivamente. Os dados foram processados para obtenção dos índices NDVI, NDWI, SAVI, VARI, IV GREEN e GLI. A eficiência na identificação dos estádios fenológicos foi determinada por análise discriminante de Anderson e o algoritmo de aprendizado de máquinas *Random Forest*. Já estimativa da produtividade foi realizada a partir da análise multivariada Análise de trilha, com uma pré filtragem utilizando correlação de Pearson representada por redes de correlações. Nenhum índice de vegetação obtido nos sistemas sensores apresentou 100% de eficácia na identificação de todos os estádios fenológicos, mas índices específicos RGB e NIR podem ser utilizados na identificação de alguns estádios fenológicos chaves, como a floração (R1 e R2), o final do desenvolvimento das vagens (R4) e desenvolvimento dos grãos dentro das vagens (R4 a R5.2). Os índices de vegetação de forma individual e em grupos RGB e NIR não são eficientes na identificação dos estádios fenológicos, o uso dos índices de forma conjunta utilizando o algoritmo Floresta Aleatória é a maneira mais eficiente para identificar os estádios fenológicos, e o sistema-sensor Sentinel-2 é superior ao sistema-sensor Amazonia-1 na identificação dos estádios fenológicos da soja. Já em relação a estimativa da produtividade, os índices SAVI e NDVI (infravermelho) possibilitaram satisfatoriamente a estimativa da produtividade da soja nos estádios V5 e R2, respectivamente, no sistema-sensor Amazonia-1, e o índice VARI (RGB) nos estádios R2 e R5.2, no sistema-sensor Sentinel-2. As resoluções espaciais utilizadas nesse estudo não foram fator limitante para a estimativa de produtividade da soja. Os índices de vegetação obtidos a partir de sensores orbitais são eficazes na identificação dos estágios fenológicos da soja de forma rápida e barata.

Palavras-chave: Fisiologia Vegetal, Sensoriamento Remoto, Sensores Orbitais, Estatística Multivariada, Aprendizado de Máquinas.

ABSTRACT

The objective was to identify Vegetation Indices with the potential to identify phenological stages and estimate soybean productivity from different sensor systems. The research was carried out in Balsas, MA, Brazil, in a central pivot area with weekly assessments of phenology and the Leaf Area Index (LAI). Spectral data from the study area were collected from the MSI and WFI sensors onboard the Sentinel-2 and Amazônia-1 satellites, respectively. The data was processed to obtain the NDVI, NDWI, SAVI, VARI, IV GREEN and GLI indices. The efficiency in identifying phenological stages was determined by Anderson discriminant analysis and the Random Forest machine learning algorithm. Productivity estimation was carried out based on multivariate analysis Track analysis, with pre-filtering using Pearson correlation represented by correlation networks. No vegetation index obtained from sensor systems was 100% effective in identifying all phenological stages, but specific RGB and NIR indices can be used to identify some key phenological stages, such as flowering (R1 and R2), the end of pod development (R4) and grain development within the pods (R4 to R5.2). Vegetation indices individually and in RGB and NIR groups are not efficient in identifying phenological stages, using the indices jointly using the Random Forest algorithm is the most efficient way to identify phenological stages, and the sensor system Sentinel-2 is superior to the Amazonia-1 sensor system in identifying soybean phenological stages. Regarding productivity estimation, the SAVI and NDVI (infrared) indices made it possible to satisfactorily estimate soybean productivity in the V5 and R2 stages, respectively, in the Amazonia-1 sensor system, and the VARI (RGB) index in the R2 stages and R5.2, in the Sentinel-2 sensor system. The spatial resolutions used in this study were not a limiting factor for estimating soybean productivity. Vegetation indices obtained from orbital sensors are effective in identifying soybean phenological stages quickly and cheaply.

Keywords: Plant Physiology, Remote Sensing, Orbital Sensors, Multivariate Statistics, Machine Learning.

1 INTRODUÇÃO

A soja (*Glycine max* L.) é a principal *commoditie* brasileira devido ter gerado, na safra 2022/23, uma receita de 345 milhões de reais, ocupando uma área de 41,1 milhões de hectares, gerando uma produção de 120,7 milhões de toneladas (IGBE, 2023). A importância dessa cultura está relacionada aos seus inúmeros usos nas indústrias, como a alimentação animal e humana, produção de cosméticos, fármacos e biodiesel. Mas, além da sua importância econômica e nutricional, esta cultura também possui importância social devido a mão de obra necessária dentro do sistema de produção e processamento, gerando empregos e desenvolvimento regional (SILVA et al., 2022).

É uma planta herbácea, da classe *Rosidaeae*, ordem *Fabales* e família *Fabaceae*, autógama, é uma planta anual ereta, que apresenta variabilidade para algumas características morfológicas, que são influenciadas pelo ambiente, como o ciclo, quantidade de ramificações, a altura e ao tipo de crescimento (SILVA et al., 2022). O caule é pubescente e ramificado e inicia o seu desenvolvimento no eixo embrionário, o sistema radicular é pivotante ramificado, com a raiz principal bem desenvolvida e as raízes secundárias em grande número, ricas em nódulo de bactérias fixadoras de nitrogênio atmosférico denominadas rizóbios e as folhas, durante seu crescimento e desenvolvimento, apresenta três tipos de folhas (FREITAS, 2019).

As flores da soja são autofecundadas antes da antese (abertura dos botões florais), que nascem em racemos axilares e são zigomorfas, com frutos que são vagens oblongas e pendentes, pubescentes e com 25 a 75 mm de comprimento, contendo de 0 a 5 sementes redondas, mas na maioria dos genótipos apresentam de 2 a 3 sementes (JUNIOR; VERNETTI, 2009).

A cultura ganhou destaque no Brasil, favorecendo maiores produtividades e superando recordes ano após ano, devido ao adequado manejo realizado, com a escolha de cultivares adaptadas a cada região, manejo do solo, nutrição mineral adequada, tratamentos culturais e manejo fitossanitário, que garante estandes uniformes e tolerantes aos estresses bióticos e abióticos durante o estabelecimento da cultura sem afetar seu potencial produtivo (FRANÇA NETO et al., 2016).

Todavia, o sistema produtivo da soja ainda enfrenta problemas, como a identificação dos estágios fenológicos corretamente em grandes áreas e com datas de semeadura distintas, e estimar a produtividade de grandes áreas antes da colheita, possibilitando a correção no manejo quando observada baixa produtividade.

O sensoriamento remoto, por meio da interação da radiação eletromagnética – planta – sensor, apresenta elevado potencial para identificação das condições dos cultivos agrícolas uma

vez que permite avaliação não destrutiva, de forma rápida e com custo relativamente baixo, onde por meio de sensores de campo é possível identificar o desenvolvimento e condição da cultura da soja interagindo com o ambiente, permitindo melhor manejo e tomada de decisões em relação às práticas culturais (CRUSIOL et al., 2017). As técnicas de sensoriamento remoto (SR), utilizando os índices de vegetação (IVs), apresentam a relação entre a radiação solar e os tecidos fotossinteticamente ativos das plantas buscando realçar as informações sobre a fitomassa verde, contida na radiância refletida pelos dosséis da vegetação, por meio da combinação de bandas espectrais da faixa do visível e infravermelho próximo (FORMAGGIO; SANCHES, 2017).

Os IVs são classificados levando em consideração sua associação predominante com a estrutura da vegetação, bioquímica e fisiologia, sendo divididos em índices intimamente relacionados ao esverdeamento e pigmentos foliares, como a clorofila e carotenoides, índices associados ao conteúdo de água nas folhas/copa e que indicam estresse no dossel (alterações no pigmento), índices que expressam eficiência no uso da luz e índices que mostram variações espectrais associadas à posição do comprimento de onda da borda do vermelho (red edge), que podem ser afetadas por alterações na concentração de clorofila ou no estresse hídrico (GALVÃO et al., 2018).

Os IVs, a partir de correlação dos dados de produtividade, dados biométricos e dados espectrais da cultura, podem indicar correlações positivas ou negativas importantes para determinar e estimar a produtividade da soja (TRINDADE; ALVES; NOETZOLD, 2017). Além de possibilitar estimar os estádios fenológicos da cultura, pois essa variável pode ser diretamente correlacionada com a quantidade de biomassa da vegetação e índice de área foliar (IAF) (BARIANI et al., 2015).

2 OBJETIVOS

2.1 Objetivo geral

Identificar Índices de Vegetação com potencial para identificar os estádios fenológicos e estimar a produtividade da soja a partir de diferentes sistemas-sensores.

2.2 Objetivo específicos

- a. Identificar Índices de Vegetação com potencial para identificar os estádios fenológicos da soja;
- b. Identificar Índices de Vegetação com potencial para estimar a produtividade da soja;
- c. Identificar Índices de Vegetação com potencial para identificar os estádios fenológicos da soja via análise *Random Forest*;
- d. Analisar a influencia na diferença da resolução espacial dos sistemas-sensores estudados para identificar estádios fenológicos e estimar produtividade.

REFERÊNCIAS

- BARIANI, C. J. et al. Monitoramento da fenologia da soja irrigada usando perfis de série temporal de NDVI. In: **INOVAGRI INTERNATIONAL MEETING**. P. 1610-18, 2015.
- CRUSIOL, LGT *et al.* Sensoriamento remoto aplicado ao monitoramento do déficit hídrico na cultura da soja. In: **Embrapa Soja-Artigo em anais de congresso (ALICE)**. In: JORNADA ACADÊMICA DA EMBRAPA SOJA, 12., 2017, Londrina. Resumos expandidos... Londrina: Embrapa Soja, 2017. p. 119-127., 2017.
- FORMAGGIO, A.R.; SANCHES, I.D. Sensoriamento Remoto em agricultura. São Paulo, **Oficina de Textos**, 235p., 2017.
- FRANÇA NETO, J. B. *et al.* Tecnologia da produção de semente de soja de alta qualidade. **Embrapa Soja**, Londrina, 2016.
- FREITAS, I. L. **Fitotecnia: soja e milho**. Londrina: Editora e Distribuidora Educacional S.A., 2019.
- GALVÃO, L. S. et al. **Crop type discrimination using hyperspectral data**. 2ed. Boca Raton: CRC Press, 2018, p. 183–210
- IBGE. Instituto Brasileiro de Geografia e Estatística. **Produção agrícola Municipal – PAM**. 2022. Disponível em: <https://www.ibge.gov.br/explica/producao-agropecuaria/>. Acesso em: 10 nov. 2023.
- SILVA, F. *et al.* **Soja: do plantio à colheita**. 2 ed. São Paulo. Oficina de Textos, 2022.
- TRINDADE, FS; ALVES, M. de C.; NOETZOLD, Rafael. Análise de perfis temporais de NDVI e EVI no ciclo fenológico da cultura de soja e sua aplicação em sojicultura de precisão. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 18, n. 2017, pág. 3878-3885, 2017.
- VERNETTI, F. J.; JUNIOR, F. J. V. Genética da soja: caracteres quantitativos e diversidade genética. Brasília: **Embrapa Informação Tecnológica**, p. 221, 2009.

CAPÍTULO 1. ÍNDICES DE VEGETAÇÃO COM DIFERENTES RESOLUÇÕES ESPACIAIS NO RECONHECIMENTO DA FENOLOGIA DA SOJA

Airton Andrade da Silva^{1 ¶*}, Francisco Charles dos Santos Silva^{2¶*}

¹ Departamento de Agronomia, Universidade Estadual do Maranhão, Balsas, MA, Brasil;

² Departamento de Agronomia, Universidade Estadual do Maranhão, Balsas, MA, Brasil;

*Correspondência do autor.

E-mail: silvaxtp@gmail.com

E-mail: franciscocharlessilva@professor.uema.br

¶ Esses autores contribuíram igualmente para esse trabalho.

Escrita e edição, Airton Andrade da Silva (AAS), Pesquisa em campo, AAS e Francisco Charles dos Santos Silva (FCSS); Análise estatística, AAS e FCSS; Correções, FCSS.

Resumo

O objetivo foi avaliar a eficiência de Índices de Vegetação (IV) na identificação dos estádios fenológicos da soja a partir de sistemas sensores orbitais com diferentes resoluções espaciais. A pesquisa foi realizada, em Balsas, MA, Brasil, numa área de pivô central com avaliações semanais da fenologia e do Índice de Área Foliar (IAF). Foram coletados dados espectrais da área de estudo a partir dos sensores MSI e WFI embarcados nos satélites Sentinel-2 e Amazônia-1, respectivamente. Os dados foram processados para obtenção dos índices NDVI, NDWI, SAVI, VARI, IV GREEN e GLI. A eficiência na identificação dos estádios fenológicos foi determinada por análise discriminante de Anderson, onde as melhores classificações foram as que apresentaram a menor Taxa de Erro Aparente (TEA). Os resultados do estudo demonstraram que a diferença da resolução espacial dos sensores não é fator determinante na identificação correta dos estádios fenológicos. Além disso, verificou-se que nenhum índice de vegetação obtido nos sistemas sensores apresentou 100% de eficácia na identificação de todos os estádios fenológicos, mas índices específicos RGB e NIR podem ser utilizados na identificação de alguns estádios fenológicos chaves, como a floração (R1 e R2), o final do desenvolvimento das vagens (R4) e desenvolvimento dos grãos dentro das vagens (R4 a R5.2). Os índices de vegetação obtidos a partir de sensores orbitais são eficazes na identificação dos estágios fenológicos da soja de forma rápida e barata.

Abstract

The present study aimed to evaluate and identify the efficiency of different vegetation indexes (VI) in distinguishing the phenological stages of soybean crops, using images collected by sensor systems, with different spatial resolutions. The research was carried out in a soybean cultivation area irrigated by central pivot, in Balsas, MA, Brazil, where weekly assessments of phenology and leaf area index were carried out. Throughout the crop cycle, spectral data from the study area were collected from the MSI and WFI sensors onboard the Sentinel-2 and Amazonia-1 satellites, respectively. The images obtained were processed to obtain vegetation

indexes based on NIR (NDVI, NDWI and SAVI) and RGB (VARI, IV GREEN and GLI), for the different phenological stages of the crop. The efficiency in identifying soybean phenological stages using vegetation indexes was determined using Anderson's discriminant analysis, where the best classifications were those with the lowest apparent error rate (AER). The difference in spatial resolution of the sensors is not a determining factor in the correct identification of soybean phenological stages. Although no vegetation index obtained from the Amazonia-1 and Sentinel-2 sensor systems was 100% effective in identifying all phenological stages of the soybean crop, specific RGB and NIR indexes can be used to identify some phenological stages. keys to soybean cultivation are the flowering of the crop (R1 and R2), the end of pod development (R4) and the stages that characterize the development of grains within the pods (R4 to R5.2). This demonstrates that vegetation indexes obtained from orbital sensors are effective in identifying soybean phenological stages quickly and cheaply.

Introdução

A soja [*Glycine max* (L.) Merrill] é uma cultura de importância econômica, devido a receita gerada a partir das suas inúmeras utilidades e subprodutos criados; relevância social, devido a geração de emprego ocasionando em desenvolvimento regional, e, principalmente, por garantir a segurança alimentar mundial, visto que pode ser utilizada na nutrição humana e animal [1]. Assim, pesquisas que visem agregar tecnologias e conhecimento dentro do sistema de produção da soja, buscando o aumento na produtividade, são essenciais.

Nesse aspecto, a agricultura de precisão tornou-se aliada no processo de otimização da produção da soja, auxiliando na tomada de decisão das práticas agrícolas a partir da interpretação e a integração de informações de diferentes fontes de dados, como os sensores orbitais [2]. Entretanto, a técnica supracitada tem apresentado deficiências, em parte, devido aos menores esforços na incorporação dos princípios fisiológicos das respostas das culturas à variação ambiental, como a fenologia da cultura [3].

A fenologia da soja é uma variável importante a ser considerada nas tomadas de decisões durante a conjunção da lavoura, como na escolha da data de semeadura, decisão no manejo de irrigação [4], no manejo do acamamento [5], na aplicação foliar de nutrientes [6], e/ou manejo fitossanitário [7]. Porém, a identificação do estágio fenológico correto em grandes áreas e com datas de semeadura distintas torna-se um trabalho oneroso, que demanda tempo e conhecimento técnico.

Diante desta problemática, os índices de vegetação (IV) podem ser ferramentas utilizadas para monitorar a fenologia da soja, a partir da estimativa da quantidade de energia eletromagnética refletida pelo dossel da cultura. A técnica pode ser utilizada após a interação com os pigmentos, água e os espaços intercelulares no interior da folha, disponibilizando dados sobre o estado fisiológico da planta [8].

Dentre as vantagens potenciais do uso de IV para o monitoramento da fenologia da soja, está a rapidez na obtenção das imagens, que são disponibilizadas de forma gratuita em catálogos, nos sites das missões, e a pouca demanda de mão de obra para a avaliação [9].

Nos últimos anos, diferentes estudos tem demonstrado a eficiência do uso de IV na diferenciação dos estádios fenológicos de diferentes culturas, como por exemplo o Índice de Vegetação por Diferenciação Normalizada (NDVI) utilizado na cultura da soja [10, 11]; o Índice de Água por Diferenciação Normalizada (NDWI), para milho e soja [9]; o Índice de Vegetação Ajustado ao Solo (SAVI), em trigo, milho e soja [12, 13]; o Índice de Resistência Atmosférica Visível (VARI), para milho e soja [14]; o Índice de Resistência Atmosférica Verde Visível (IV GREEN), em arroz [15]; e o Índice Folha Verde (GLI), no milho [16].

Os índices VARI, IV GREEN e GLI, como possuem na sua composição apenas as bandas do azul, verde e vermelho, são classificados como índices RGB. Esses consideram comprimentos de ondas do espectro visível que se relacionam apenas com os pigmentos da folha (clorofila, carotenoides, antocianinas e xantofilas) que são os responsáveis por absorver (80-90%) da luz visível com pico de 0,55 μm , e refletir 10-20% da luz visível, principalmente a banda verde [17].

Os índices NDVI, NDWI e SAVI possuem informações da faixa do infravermelho-próximo (NIR) na sua composição, sendo classificados como índices NIR. Essa faixa espectral apresenta bastante sensibilidade à variação biomassa da vegetação e consequentemente à variação de crescimento e desenvolvimento das plantas [17].

Embora existam muitos índices de vegetação, são escassos os estudos sobre a eficiência de diferentes índices de vegetação na identificação dos diferentes estádios fenológicos na soja e a avaliação de diferentes sistemas-sensores com diferentes resoluções espaciais, pois os estudos disponíveis utilizam apenas uma fonte de dados espectrais.

Diante do exposto, teve-se como objetivo avaliar e identificar a eficiência de diferentes índices de vegetação (IV) na distinção dos estádios fenológicos da cultura da soja, utilizando imagens coletadas por sistemas sensores, com diferentes resoluções espaciais.

Metodologia

Local da pesquisa

A presente pesquisa foi desenvolvida entre abril e julho de 2022, em uma área de produção comercial de sementes de soja, com 80 ha, localizada a 30 Km do município de

Balsas, MA, Brasil (Fig 1), onde o cultivar de soja TMG2383 foi conduzida sob irrigação por pivô central. O local está a 7° 31' 59" Sul, 46° 2' 6" Oeste, 243 metros de altitude e apresenta clima tropical chuvoso (Aw) e temperatura média de 27,1 °C, segundo a classificação climática de Köppen. A precipitação pluviométrica média anual é de 1175 mm, com maiores precipitações nos meses de novembro a abril, quando concentram 85% do total [18].




Fig 1. Localização da área de estudo.

O solo da área experimental foi classificado como Latossolo Vermelho. Os dados meteorológicos de temperatura, precipitação e nebulosidade referentes ao período do estudo (Fig 2) foram obtidos pela estação meteorológica do Instituto Nacional de Meteorologia (INMET) presente na região do estudo.




Fig 2 - Dados de temperatura, precipitação total e nebulosidade durante os meses de execução do experimento em Balsas no ano 2022 [19].

Condução do experimento

O experimento foi instalado em delineamento de blocos casualizados, com quatro repetições. Cada repetição foi constituída de uma área de 5 metros de raio, para os produtos Sentinel-2, e 30 metros de raio, para os produtos Amazonia-1, cujos centros foram demarcados com um receptor Global Positioning System (GPS) de navegação.

Após a germinação da soja, foi realizado visualmente o monitoramento semanal da fenologia das plantas, de acordo com Oliveira Júnior et al. [20] (Tabela 1), e do índice de área foliar, a partir do método do disco seco [21] adaptado para um cilindro de seção de 7 cm² e 10 discos por amostra de três plantas.

Tabela 1 - Estádios Fenológicos da soja [20].

ESTÁDIO	DESCRIÇÃO
V1	Um par de folhas unifolioladas (ou um nó);
V2	Primeiro trifólio completamente desenvolvido (ou dois nós);
V3	Dois trifólios completamente desenvolvidos (ou três nós);
Vn	Estádios vegetativos até chegas ao reprodutivo a partir da emissão do primeiro botão floral;
R1	Uma flor aberta em qualquer nó na haste principal;
R2	Uma flor aberta em um dos dois nós superiores na haste principal com folha completamente desenvolvida;
R3	Vagem de 0,5 cm a 2,0 cm em um dos quatro nós superiores na haste principal;
R4	Vagem completamente desenvolvida (> 2,0 cm) em um dos quatro nós superiores na haste principal;
R5.1, R5.2, R5.3, R5.4 e R5.5	Início do enchimento de grãos (<10% até 100% de granação) em um dos quatro nós superiores da haste principal;
R6	Grão cheio ou completo em um dos quatro nós superiores na haste principal;
R7	Início da maturação. Uma vagem com coloração de madura na haste principal;
R8	Maturação Plena (colheita). Mais de 95% das vagens com coloração de madura.

Imagens coletadas pelo sensor *Multispectral Imager* (MSI), embarcado no satélite Sentinel-2, foram utilizadas como fonte de dados de reflectância, as quais foram obtidas do catálogo de imagens do Centro de Acesso Aberto *Copernicus* (<https://scihub.copernicus.eu/dhus/#/home>), em nível de processamento L2A. As imagens L2A possuíam correção para nuvens e sombras de nuvens, espessura óptica de aerossol, vapor de água, reflectância de superfície ortorretificada com precisão de registro multiespectral, e multitemporal de subpixel. O sensor disponibilizou produtos com resolução temporal de 5 dias, resolução espacial, que varia de 10 m a 65 m, resolução radiométrica de 10 bits e resolução espectral de 13 bandas, porém, no presente estudo, foram utilizadas apenas as bandas com resolução espacial de 10 metros (Tabela 2).

Tabela 2- Especificações técnicas do sensor MSI embarcado no satélite Sentinel-2 e do sensor WFI embarcado no satélite Amazônia-2.

Satélite	Resolução Temporal	Resolução Espectral (μm)	Resolução Radiométrica	Resolução Espacial
Sentinel-2	5 dias	Azul (0,49-0,56) Verde (0,56-0,665) Vermelho (0,665-0,842) Infravermelho Próximo (0,842-0,865)	10 bits	10 m
Amazônia-1	5 dias	Azul (0,45-0,52) Verde (0,52-0,59) Vermelho (0,63-0,69) Infravermelho Próximo (0,77-0,89)	10 bits	~65 m

Imagens do sensor orbital WFI (*Wide Field Imager*), embarcado no satélite Amazônia-1, também foram utilizadas como fonte de dados de reflectância, as quais foram obtidas do catálogo de imagens do INPE – Instituto Nacional de Pesquisas Espaciais (<http://www2.dgi.inpe.br/catalogo/explore>). O sensor disponibilizou produtos com resolução de acordo com a Tabela 2.

A escolha de ambos satélites foi realizada pela resolução temporal de 5 dias, o que permite melhor monitoramento da fenologia no decorrer do ciclo da cultura, e resolução espacial de 10 e 64 m, possibilitando a comparação da qualidade dos dados. Pois, de acordo com Bariani [22] o monitoramento da fenologia, por meio de sensores orbitais, deve possuir a maior quantidade de dados durante o ciclo, favorecendo o acompanhamento dos diferentes estádios da cultura.

A resolução temporal dos sensores proporcionou a coleta de 14 imagens para o satélite Sentinel-2 e 11 imagens para o satélite Amazônia-1, ao longo do ciclo da cultura, o que possibilitou a obtenção de informações espectrais para os estádios fenológicos de V3 a R8 (Fig 3). O critério para a seleção de imagens seguiu a disponibilidade para *download* dos respectivos catálogos de imagens e que não apresentassem cobertura total de nuvens na área de estudo.




Fig 3. Aspecto morfológico da soja nos diferentes estádios fenológicos em que foram obtidas informações espectrais pelos satélites Sentinel-2 e Amazônia-1.

Adaptado Oliveira Júnior et al. [20]

Processamento das imagens

As imagens foram processadas no *software Qgis* versão 3.26.3 [23] usando como sistema de coordenadas o *Datum* Sirgas 2000 UTM Zona 23S e submetidas as equações dos IVs da Tabela 03, gerando os produtos representados nas Tabelas 3 e 4.

Tabela 3 - Índices de vegetação




























Tipo	Índice de vegetação	Nome	Equação	Referências
NIR	NDVI	Índice de Vegetação por Diferenciação Normalizada	$(B8-B4)/(B8+B4)$	[24]
	NDWI	Índice de Água por Diferenciação Normalizada	$(B3-B8)/(B3+B8)$	[25]
	SAVI	Índice de Vegetação Ajustado ao Solo	$(1+L)*[(B8-B4)÷(B8+B4+L)]$	[26]
RGB	VARI	Índice de Resistência Atmosférica Visível	$(B3-B4)/(B3+B4-B2)$	[27]
	GLI	Índice Folha Verde	$(2*B3-B4-B2) / (2*B3+B4+B2)$	[28]
	IV GREEN	Índices de resistência atmosférica Verde Visível	$(B3-B4)/(B3+B4)$	[27]

B4: refletância no vermelho, B8: refletância no infravermelho próximo, B3: refletância no verde; B2: refletância no azul; L = fator de ajuste podendo variar de 0 a 1.

1 **Tabela 4 - Comportamento dos índices ao longo do ciclo da soja para os produtos Sentinel-**
2 **2.**

IV	NDVI	NDWI	SAVI	IVGREEN	GLI	VARI
V3						
V5						
V8						
R1						
R2						
R3						
R4						
R5.1						
R5.2						
R5.4						
R5.5						
R6						
R7						
R8						

1 **Tabela 5 - Comportamento dos índices ao longo do ciclo da soja para os produtos**
2 **Amazonia-1**

IV	NDVI	NDWI	SAVI	IVGREEN	GLI	VARI
V3						
V5						
V8						
R1						
R2						
R4						
R5.1						
R5.2						
R5.4						
R5.5						
R8						

3

4

1 Estatística

2
3 Com auxílio programa Genes [29] os dados obtidos foram submetidos ao teste F da
4 análise de variância, onde se buscou verificar a existência de diferença significativa entre as
5 repetições e entre os estádios fenológicos, ao longo do ciclo da cultura, para os diferentes
6 índices de vegetação (IV). Os valores dos IVs que apresentaram diferenças entre os estádios
7 fenológicos, ainda por meio do programa Genes, foram submetidos a análise discriminante de
8 Anderson [30], a fim de quantificar a eficiência de cada IV na diferenciação dos estádios
9 fenológicos da cultura.

10 A análise discriminante foi inicialmente abordada por Fisher [31], e consiste em obter
11 funções matemáticas capazes de classificar uma amostra em um de vários grupos com base em
12 características desses grupos, buscando minimizar a probabilidade de má classificação, isto é,
13 minimizar a probabilidade de classificar erroneamente um indivíduo em uma população,
14 quando realmente pertence a outra população. Essa análise é uma técnica estatística
15 multivariada utilizada para discriminar e classificar objetos se aplicada de acordo com a
16 (Equação 1).

$$D_i(\tilde{x}) = \tilde{L}_i \cdot \tilde{x} - \frac{1}{2} \cdot \tilde{L}_i \cdot \tilde{\mu}_i + \ln(p_i) \quad (1)$$

17 Onde: $D_i(\tilde{x})$ = função discriminante da população 'i' do vetor aleatório $\tilde{x}$; $\tilde{L}_i$ = vetor aleatório
18 discriminante da população 'i'; $\tilde{x}$ = vetor aleatório de características; $\tilde{\mu}_i$ = vetor de médias da
19 população 'i'; p_i = probabilidade de ocorrência da população 'i'

20 Uma das maneiras de avaliar a eficiência das funções discriminantes é por meio da taxa
21 de erro aparente, devido ser definida em função das observações na amostra que estão mal
22 classificadas pela função discriminante. A eficiência das funções discriminantes em classificar
23 corretamente cada estágio fenológico foi estimada pela taxa de erro aparente (Equação 2), onde
24 maiores valores indicam menor precisão na diferenciação.

$$TEA = \frac{1}{N} \cdot \sum_{i=1}^n m_i \quad (1)$$

25 Onde: TEA = taxa de erro aparente; m_i = número de observações erradas nos grupos; N =
26 número total de classificações.

27

28

Resumo da metodologia

Um resumo da metodologia utilizada na presente pesquisa está ilustrado na Fig 4.




Fig 4. Metodologia da pesquisa.

Resultados e Discussão

Todos os índices se portaram de acordo com o padrão relatado na literatura [32, 33, 34, 35], demonstrando a qualidade das informações espectrais obtidas (Fig 5).




Fig 5. Comportamento dos índices de vegetação (IVs) NDVI, NDWI, SAVI (tipo NIR), e VARI, GLI e IV GREEN (tipo RGB) nos satélites Sentinel-2 e Amazônia-1.

Vários autores relatam que o comportamento espectral da soja ao longo do ciclo apresenta baixos valores no início do ciclo, cresce gradualmente até um máximo de biomassa e decresce com o término do ciclo da cultura [36, 10, 12, 13, 14, 15, 16] (Fig 5). O índice NDWI apresentou comportamento semelhante ao supracitado, porém a curva foi inversa devido seus valores serem negativos de acordo com o relatado por Bolton e Friedl [9] (Fig 5).

Os índices de vegetação discutidos neste estudo se dividem em duas categorias: índices RGB e índices que se baseiam no infravermelho-próximo (NIR). Os índices VARI, IV GREEN

e GLI, que são compostos apenas pelas bandas azul, verde e vermelha, são categorizados como índices RGB, e estão associados apenas aos pigmentos da folha (clorofila, carotenoides, antocianinas e xantofilas). Por outro lado, os índices NDVI, NDWI e SAVI incluem informações da faixa do infravermelho-próximo (NIR), que é altamente sensível à variação da biomassa vegetal e, conseqüentemente, à variação do crescimento e desenvolvimento das plantas [17]. A relação desses índices com aspectos morfofisiológicos das plantas explica a capacidade dos mesmos em identificar as mudanças dos estádios fenológicos da soja mencionados anteriormente.

Na Fig 5 é possível observar que todos os índices de vegetação analisados, em ambos sistemas sensores (Sentinel-2 e Amazonia-1), apresentaram diferenças significativas entre os estádios fenológicos, a 5% de probabilidade, pelo teste F da análise de variância, possibilitando quantificar a eficiência de distinção dos estádios fenológicos da cultura da soja para cada índice de vegetação, via análise discriminante.

Para o sistema-sensor Sentinel-2, a análise discriminante para os índices NDVI, NDWI e SAVI apresentaram as maiores taxas de erros aparente (TEA), com 62,5, 60,7 e 62,5%, respectivamente, ou seja, menos de 50% de eficiência na identificação dos estádios fenológicos corretos. O índice IV GREEN proporcionou a melhor eficiência na identificação correta dos estádios fenológicos, com TEA de apenas (56,2%) (Tabela 6). Já para os produtos do sistema-sensor Amazonia-1, a análise discriminante para NDVI, IV GREEN, VARI, GLI e SAVI apresentaram as maiores TEA, 70,4, 64,7, 63,6, 60,2 e 57,9%, respectivamente, sendo a menor para o índice NDWI (53,4%) (Tabela 6).

Tabela 6 - Taxa de Erro Aparente (TEA) (%) dos índices para os sistemas-sensor Sentinel-2 e Amazonia-1, obtidos via Funções Discriminante de Anderson.

Satélite	NIR	RGB
Sentinel-2	NDVI = 62,5	VARI = 59,8
	NDWI = 60,7	IV GREEN = 56,2
	SAVI = 62,5	GLI = 58,9
Amazonia-1	NDVI = 70,4	VARI = 63,6
	NDWI = 53,4	IV GREEN = 64,7
	SAVI = 57,9	GLI = 60,2

Nogueira et al. [37] conseguiram classificar diferentes características para diferenciar cultivares de soja, a partir da função discriminante, com menor taxa de erro aparente. Das et al.

[38], utilizaram a análise discriminante para avaliar o poder discriminativo de 17 comprimentos de onda de 14 genótipos de arroz, ao obter taxa de erro aparente de 2%. Já, a partir da análise discriminante, com taxa de erro aparente de 3%, conseguiram classificar características para discriminar grupos varietais e híbridos de *Coffea canephora* [39]. Assim é nítido o poder da análise discriminante, tendo como parâmetro de eficiência a menor taxa de erro aparente, para discriminar estádios de desenvolvimento da soja a partir de Índices de Vegetação.

Nenhum índice de vegetação obtido nos sistemas sensores Amazônia-1 e Sentinel-2 apresentou 100% de eficácia na identificação dos estádios fenológicos da cultura da soja, o que demonstra a impossibilidade do uso desses índices na identificação simultânea de todos os estádios da cultura. Por outro lado, alguns índices apresentaram eficiência de 87,5 a 100% na identificação de estádios fenológicos específicos (Fig 6).




Fig 6 - Porcentagem de classificações corretas dos estádios fenológicos da soja, por meio dos índices de vegetação NIR (NDVI, NDWI e SAVI) e RGB (IV GREEN, GLI e VARI) dos satélites Sentinel-2 e Amazônia-1, via análise discriminante.

Apesar de nenhum índice de vegetação obtido nos sistemas sensores Amazônia-1 e Sentinel-2 ter apresentado 100% de eficácia na identificação simultânea de todos os estádios fenológicos da cultura da soja (Fig 6). Alguns índices possibilitaram a identificação correta dos estádios V3, R1, R2, R4, R5.1, R5.2 e R8 (Fig 6).

Para os estádios vegetativos de desenvolvimento da soja, a única classificação correta ocorreu para o estágio V3, com aplicação do índice NDWI, obtido a partir de dados espectrais do satélite Amazonia-1 (Fig 6).

A identificação correta do estágio V3 é importante, uma vez que, nessa fase de desenvolvimento da soja é recomendada a aplicação de cobalto, molibdênio e níquel via foliar [40], aplicação complementar de inoculante, via pulverização, controle do tamanduá-da-soja (*Sternechus subsignatus*) [41] e aplicação de herbicidas pós-emergente [42].

As classificações corretas dos estádios que marcam a floração da cultura da soja, R1 (início da formação) e R2 (floração plena), foi eficaz com base nos dados do Sistema Sensor Sentinel-2 e Amazonia-1 (Fig 6). Sendo o estágio R1 identificado com sucesso pelos índices IVGreen e VARI do Sentinel-2 e pelo índice GLI do Amazonia-1. O estágio R2 foi corretamente identificado pelos índices baseados em NIR (NDVI e SAVI) do Sentinel-2 e pelos índices do tipo RGB (IV Green e VARI) do sistema sensor Amazonia-1.

A identificação correta desses estádios é primordial para determinação do momento adequado para aplicação de medidas de manejo nutricionais, fitossanitárias e predição de produtividade. O estágio R1, por exemplo, nas cultivares de soja de crescimento determinado, é ideal para avaliação do estado nutricional da planta por diagnose foliar, e R2 para cultivares de crescimento indeterminado [43]. Nesses estádios que ocorrem as aplicações de defensivos para o controle de mofo-branco (*Sclerotinia sclerotiorum*), ferrugem asiática (*Phakopsora pachyrhizi*), Mancha-parda (*Septoria glycines*), Oídio (*Erysiphe diffusa*), Mancha-alvo (*Corynespora cassiicola*) e Antracnose (*Colletotrichum truncatum*) [44]. Nesse estágio [45] definiram como o melhor estágio para a predição de produtividade na cultura da soja a partir do Índice de Vegetação por Diferença Normalizada (NDVI).

Quanto aos estádios reprodutivos, que marcam o desenvolvimento das vagens, apenas o estágio R4 (vagem totalmente formada) foi identificado com sucesso. Sendo a identificação correta realizada pelo sensor Sentinel-2, por meio do índice RGB VARI, e pelo Sistema Sensor Amazonia-1 (Fig 6). Silva et al. [46] definiram este estágio como o melhor momento para a predição de produtividade na cultura da soja a partir de Índice de Vegetação Ajustado ao Solo (SAVI). Nesse estágio, que marca o início mais crítico de desenvolvimento, no que tange ao rendimento, a irrigação suplementar pode ser uma prática recomendada com o objetivo de reduzir o abortamento [47].

Os estádios R5.1 e R5.2, que caracterizam o desenvolvimento dos grãos dentro das vagens, foram identificados de forma precisa (Fig 6). As informações espectrais do satélite Sentinel-2 possibilitaram a identificação correta do estágio R5.1, por meio dos índices NDWI

e GLI, e do estágio R5.2, pelo índice SAVI. Os índices NDWI e SAVI, obtidos por meio dos dados do satélite Amazonia-1, possibilitaram a classificação correta do estágio R5.1. Tais fases de desenvolvimento da soja são caracterizados pelo máximo requerimento de nutrientes e água, sendo recomendado o manejo de irrigação suplementar em caso de déficit hídrico, favorecendo a absorção de nutrientes do solo, além do enriquecimento de sementes com molibdênio e predição de produtividade, a partir do Índice de Resistência Atmosférica Visível [47, 41, 48].

O estágio R8, que marca a maturação plena da cultura da soja, foi identificado corretamente apenas pelo índice GLI, obtido a partir de dados espectrais do satélite Amazonia-1 (Fig 6). Esse estágio serve como tomada de decisão para aplicação de dessecantes, favorecendo a perda de água até 13-14% de umidade, possibilitando uma adequada colheita [41].

Os sistemas-sensores estudados apresentaram eficácia semelhante na identificação de estádios fenológicos da soja, sendo ambos aptos na identificação dos estádios R1, R2, R4 e R5.1. No entanto, o satélite Amazonia-1 apresentou superioridade com a identificação precisa dos estádios V3 e R8, demonstrando que a resolução espacial de 64 metros, do sensor Wide Field Imager (WFI) embargado nesse satélite, não é fator limitante para a identificação de alguns estádios fenológicos da soja, ao menos em grandes áreas de cultivos, como foi o caso desse estudo. Todavia, são necessários estudos para averiguar a eficiência desse sistema sensor na identificação de estádios fenológicos da soja com a variação da área de cultivo imaginada.

Gao et al. [49], conseguiu diferenciar os estágios iniciais de crescimento da soja e milho utilizando as resoluções espaciais de 10 e 30m do sensor MSI do satélite Sentinel-2, demonstrando que resoluções espaciais diferentes possuem eficácia parecida para o monitoramento da fenologia em soja.

Quanto aos tipos de índices de vegetação, para os estádios reprodutivos R1, R2, R4 e R5.1, os índices RGB foram tão eficientes quanto os índices que possuem a banda do NIR.

Índices RGB como o VARI, VIgreen e GLI tem recebido bastante atenção devido a possibilidade de sua aplicação partir dos dados coletados por câmeras simples e de baixo custo que podem ser embarcadas em veículos aéreos não tripulados (VANTs) [50]. Assim, os resultados desse estudo abrem a possibilidade do uso de sensores RGB em VANTs para diferenciar com maior praticidade e agilidade os estádios reprodutivos da soja [51].

Em trabalhos realizados por Vergara-Diaz et al. [52], Zhou et al. [53] e Gracia-Romero et al. [54], foi observado que índices RGB, em relação a índices que usam a banda do infravermelho, demonstraram um alto rendimento para a previsão precisa de rendimento de grãos, concentração de Nitrogênio e Fósforo na folha, proporção de carbono para nitrogênio

1 sob uma ampla gama de níveis de fertilização de nitrogênio e efeitos das aplicações de
2 fertilizantes fosfatados, na cultura do milho, e potencial de uso na seleção de cultivares de soja
3 com tolerância à seca.

4 Outro ponto importante demonstrado pelos resultados é que, independentemente do tipo
5 sistema sensor ou do tipo de índice de vegetação, as maiores taxas de eficácia na classificação
6 dos estádios fenológicos foram obtidas para os estádios reprodutivos de R1, R2 (floração), R4
7 (vagem desenvolvida), R4, R5.1 e R5.2 (desenvolvimento dos grãos). A possível explicação
8 para esse resultado está na variação da magnitude dos valores dos índices de vegetação ao longo
9 do ciclo da cultura.

10 Como pode ser observado na fig 5 o comportamento espectral da soja ao longo do ciclo
11 apresenta baixos valores no início do ciclo, cresce gradualmente e decresce à medida que o
12 término do ciclo da cultura se aproxima [36, 10, 12, 13, 14, 15, 16]. Mesmos os índices RGB
13 que apresentam menor magnitude de variação de seus valores ao longo do ciclo da cultura,
14 também apresentaram o mesmo padrão de variação como pode ser observado para o índice
15 VARI do satélite Sentinel-2 (Fig 5).

16 Tal comportamento espectral supracitado resulta na proximidade e até coincidência dos
17 valores dos índices de vegetação entre os estádios iniciais e finais, assim como na semelhança
18 entre os valores dos índices nos estádios reprodutivos finais, R6 a R8. Essa semelhança de
19 valores inviabiliza a distinção efetiva dos estádios fenológicos iniciais e dos estádios finais de
20 desenvolvimento da cultura. Restando os estádios reprodutivos de R1 a R5.2, com valores mais
21 divergente para os índices do que os demais estádios, o que resulta nas maiores taxas de
22 eficiência na identificação desses estádios fenológicos. Resultados semelhantes foram obtidos
23 para o arroz por Qiin et al. [55] utilizando aprendizado de máquina na identificação dos estádios
24 fenológicos da cultura.

25 Para corroborar com esses resultados, o mesmo padrão de variação é observado para o
26 índice de área foliar (IAF) (Fig 7). O IAF é definido como a relação entre a área foliar de uma
27 planta e a área de solo ocupada pela mesma, possuindo elevada correlação entre índices
28 espectrais [56, 21].

29




Fig 7 - Box Plot para o índice vegetativo VARI, do satélite Sentinel-2, e para o índice de área foliar (IAF) da soja.

Diversos autores, ao estudarem o comportamento espectral da soja, milho, trigo e arroz, a partir de índices de vegetação do tipo RGB e Infravermelho, observaram pouca variação nos valores dos índices durante os estádios reprodutivos [11, 10, 9, 12, 13, 14, 15, 16].

Apesar de nenhum índice de vegetação ter sido eficiente na identificação de todos estádios fenológicos da cultura da soja, os índices foram eficazes na identificação de estádios específicos, demonstrando a possibilidade do uso da técnica no manejo da cultura da soja. Ademais, a disponibilidade de modo gratuito de dados de refletância bem como de softwares para processamento, torna o não uso desse modo de monitoramento do desenvolvimento da cultura da soja injustificada.

Entretanto, novos estudos que englobem outros índices de vegetação, bem como a aplicação de combinações e/ou do uso simultâneo de índices de vegetação para o refinamento da identificação dos estádios fenológicos da soja via sensoriamento remoto se fazem necessários.

Conclusões

A diferença da resolução espacial dos sensores não é fator determinante na identificação correta dos estádios fenológicos da soja.

Nenhum índice de vegetação obtido nos sistemas sensores Amazônia-1 e Sentinel-2 apresentou 100% de eficácia na identificação de todos os estádios fenológicos da cultura da soja. Mas índices de vegetação RGB e NIR podem ser utilizados na identificação correta dos

estádios que marcam a floração da cultura (R1 e R2), o final do desenvolvimento das vagens (R4) e os estádios que caracterizam o desenvolvimento dos grãos dentro das vagens (R4 a R5.2), na cultura da soja.

Os índices de vegetação obtidos a partir de sensores orbitais são eficazes na identificação dos estágios fenológicos da soja de forma rápida e barata.

Estudos envolvendo modelagens estatísticas não lineares devem ser realizados na identificação dos estágios fenológicos na cultura da soja, visto a similaridade dos valores dos índices nos estádios iniciais e finais da cultura.

Referências

1. Silva F, Borem A, Sedyama T, Câmara G. Soja: do plantio à colheita. 2ª edição. São Paulo: Oficina de Textos;2022.
2. Molin JP, Bazame H, Maldaner R, Corredo L, Martello M. Agricultura de precisão e as contribuições digitais para a gestão localizada das lavouras. Revista Ciência Agronômica. 2021;51. Português.
3. Monzon JP, Calvino P, Sadras V, Zubiaurri J, Andrade F. Precision agriculture based on crop physiological principles improves whole-farm yield and profit: A case study. European Journal of Agronomy. 2018;99:62-71.
4. Gava R, Frizzon J, Snyder R, Almeida B, Freitas P, Rezende R. Estratégias de manejo de déficit hídrico na irrigação da cultura da soja. Revista Brasileira de Engenharia de Biosistemas. 2016;10(3):305-315. Português.
5. Foloni J, Henning F, Mertz-Hernning L, Rodrigues R, Mellos L, Neumaier N. Manejo de acamamento de cultivares de soja com lactofem em diferentes ambientes de produção. VII Congresso Brasileiro da Soja, Goiania, Brasil, 2018. Português.
6. Ecco M, Backes J, Reuter R. Manejo de aplicação de boro no cultivo da soja. Revista Científica Rural. 2022;24:12-25. Português.
7. Drehmer RG, Lajus CR, Cericato A. Rendimento da soja submetida a adição de fungicida multissítio em diferentes estádios fenológicos. Anuário Pesquisa e Extensão Unoesc São Miguel do Oeste. 2018;3:18891-18891. Português.
8. Oliveira M, Queiroz T, Teixeira A, Moreira L, Leão R, Espectrometria de reflectância aplicada à análise das deficiências de nitrogênio e potássio em algodoeiro. Revista Ciência Agronômica. 2020;51(4). Português.

9. Bolton D, Friedl M. Forecasting Crop Yield Using Remotely Sensed Vegetation Indexes and Crop Phenology Metrics. *Agricultural and Forest Meteorology*. 2013;173:74-84.
10. Estevam V, Reges N, Dos Santos M. Uso do índice ndvi para determinação fenológica da cultura da soja. *Revista uniaraguaia*. 2023;18:106-115. Português.
11. Neiverth W, Crusiol L, Carvalho J, Ferreira L, Rio A, Silbadelli R, et al. NDVI de estádios fenológicos da soja BRS 284 de crescimento indeterminado em casa de vegetação. *Embrapa Soja*. 2013:204-209. Português.
12. Breaban LG, Stoleriu AP. Monitoring the crops phenology using time series sentinel 2 images. *Acta Geobalcanica (Skopje.Online)*. 2020;6:95-102.
13. Hatfield J, Pruger J. Value of Using Different Vegetative Indexes to Quantify Agricultural Crop Characteristics at Different Growth Stages under Varying Management Practices. *Remote Sens*. 2010;2:562-579.
14. Sakamoto T, Gitelson A, Nguy-Rbertson A, Arquebauer T, Wardlow B, Suyker A, et al. An Alternative Method Using Digital Cameras for Continuous Monitoring of Crop Status. *Agricultural and Forest Meteorology*. 2012;154:113-26.
15. Ge H, MA F, Li Z, Tan Z, Du C. Improved Accuracy of Phenological Detection in Rice Breeding by Using Ensemble Models of Machine Learning Based on UAV-RGB Imagery. *Remote Sensing*, 2021;11:2439.
16. Guo Y, Xiao Y, Hao F, Zhang X, Sol H, Beurs K, et al. Identifying crop phenology using maize height constructed from multi-sources images. *International Journal of Applied Earth Observation and Geoinformation*. 2022;115:103-121.
17. Ponzoni FJ, Shimabukuro, Y. E.; Kuplich, T. M. Sensoriamento remoto da vegetação. 2. ed.; Oficina de Textos: São Paulo, Brasil, 2012, 160.
18. Passos ML, Zambrzycki, GC, Pereira RS. Balanço hídrico climatológico e classificação climática para o município de Balsas - MA. *Revista Scientia Agraria*. 2017;18:83-89. Português.
19. Inmet, Instituto Nacional de Meteorologia do Brasil. Disponível em: <https://portal.inmet.gov.br/>. Acessado em: 17 out. 2022.
20. Oliveira Júnior A, Castro C, Pereira L, Domingos C. Estádios fenológicos e marcha de absorção de nutrientes da soja. *Embrapa Milho e Sorgo-Boletim de Pesquisa e Desenvolvimento (INFOTECA-E)*, 2016. Português.
21. Souza AL, Costa M, Sena Júnior D, Paz R. Avaliação de três métodos de obtenção do índice de área foliar para cultura da soja. *Nativa*. 2019;7:284-287. Português.

22. Bariani C, Kerstini DS, Victoria NM, Carlesso R, Petry MT, Peripolli M. Monitoramento da fenologia da soja irrigada usando perfis de série temporal de NDVI. III encontro internacional INOVAGRI. 2015:1610-1618. Português.
23. QGIS. Geographi Information System QGIS. Disponível em: <http://www.qgis.org>. Acesso em: 09 maio 2022.
24. Rouse JW, Haas RH, Schell JA, Deering DW, Harlan JC. Monitoring the vernal advancement and retrogradation of natural vegetation. Greenbelt: National Aeronautics and Space Administration. 1974:371.
25. Mc Feeters SK. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing. 1996;17:1425-1432.
26. Huete AR. A soil ajusted vegetation index (SAVI). Remote Sensing Environ. 1988:25.
27. Gitelson A, Kaufman Y, Stark R, Rundquist D. Novel algorithms for remote estimation of vegetation fraction. Remote Sensing of Environment. 2002;80:76–87.
28. Louhaichi M, Borman M, Jhonson D. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. Geocarto International, 2001;16:65-70.
29. Cruz CD. Genes Software - extended and integrated with the R, Matlab and Selegen. Acta Scientiarum, 2016;38:547-552.
30. Anderson TW. An introduction to multivariate statistical analysis. 2 ed. EUA: John Wiley & Sons. 1958:242.
31. Fisher RA. The use of multiple measurements in taxonomic problems. Annals of Eugenics, 1936;7:179-188.
32. Boratto I, Gomide R. Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013. Português.
33. Fabri T, Mello G, Ferrari J, Peluzio J, Souza M. Comportamento de índices de vegetação em cafeeiros utilizando sensor multiespectral em aeronave remotamente pilotada. Revista Ifes Ciência. 2023;9:01-15. Português.
34. Medeiros R, Souza G, Figueiredo C, Formiga A, Oliveira F, Oliveira P. Resposta espectral do comportamento do NDVI e NDWI diante de diferentes intensidades pluviométricas na cidade de Patos–PB. Research, Society and Development. 2022;11: e49811326819-e49811326819. Português.

- 1 35. Venancio L, Cunha F, Mantovani E, Amaral C, Reis E. Mapeamento dos estádios
2 fenológicos da cultura do milho utilizando o NDVI derivado dos sensores OLI e MODIS.
3 Semina: Ciências Agrárias. 2019;41:1517-1534. Português.
- 4 36. Rodrigues C, Fontana D, Moraes O, Roberti D. NDVI e fluxo de CO₂ em lavoura de soja
5 no Rio Grande do Sul. Revista Brasileira de Meteorologia. 2013;28:95-104. Português.
- 6 37. Nogueira AP, Sedyama T, Cruz C, Reis M, Pereira D, Jangarelli M. Novas características
7 para diferenciação de cultivares de soja pela análise discriminante. Ciência Rural.
8 2008;38:2427-2433. Português.
- 9 38. Das B, Sahoo R, Biswas A, Pargal R, Krishna R, Verma R, et al. Discrimination of rice
10 genotypes using field spectroradiometry. Geocarto International, 2018;35(1):64-77.
- 11 39. Oliveira G, Miranda T, Nascimento A, Nascimento T, Caixeta E, Silva L, et al.
12 Discrimination of varietal groups and hybrids of *Coffea canephora* species using
13 multivariate analysis. Brazilian Journal of Biometrics, 2021;39(1):194-205.
- 14 40. Santos Neto J, Duarte I, Cardoso A, Lima R, Lana R, Torres J, et al. Sistema integrado de
15 diagnose e recomendação para soja em função das doses de níquel, cobalto e molibdênio.
16 Agrarian. 2019;12:48-56. Português.
- 17 41. Seixas C, Neumaier N, Balbinot Júnior A, Krzyanowski F, Leite R. Tecnologias de
18 Produção de Soja. 17 ed.; Embrapa Soja: Londrina: Embrapa Soja. 2020;17:347.
19 Português.
- 20 42. Galon L, Cavaletti D, Da Silva M, Da Silva A, Neto O. Seletividade e eficácia de herbicidas
21 aplicados em soja para o controle de plantas daninhas. Agrarian. 2022;15:15715-15715.
22 Português.
- 23 43. Oliveira A, Leite R, Balbinot A, Seixas C, Kern H. Soja: o produtor pergunta, a Embrapa
24 responde. 1 ed.; Embrapa: Brasília, Brasil. 2019:274. Português.
- 25 44. Embrapa. Tecnologias de produção de soja - Região Central do Brasil 2014. 16 ed.
26 Londrina: Embrapa Soja. 2013. Português.
- 27 45. Trindade F, Alves M, Noetzold R, Andrade I, Pozza A. Relação espectro-temporal de
28 índices de vegetação com atributos do solo e produtividade da soja. Revista de Ciências
29 Agrárias-Amazonian Journal of Agricultural and Environmental Sciences. 2019:62-73.
30 Português.
- 31 46. Silva E, Baio F, Teodoro L, Da Silva Júnior C, Borges R, Teodoro P. UAV-multispectral
32 and vegetation indexes in soybean grain yield prediction based on in situ observation.
33 Remote Sensing Applications: Society and Environment. 2020;18:100318.

- 1 47. Oliveira Z, Knies A, Gomes J. Produtividade de cultivares de soja com e sem irrigação
2 suplementar para a safra e safrinha de 2019/20 na região central do RS. *Brazilian Journal*
3 *of Development*. 2020;6:81268-81284. Português.
- 4 48. Bai D, Li D, Zhao C, Wang Z, Shao M, Guo B, et al. Estimation of soybean yield parameters
5 under lodging conditions using rgb information from unmanned aerial vehicles. *Frontiers*
6 *in Plant Science*. 2022;13:1012293.
- 7 49. Gao F, Craig Daughtry M, Karnieli A, Hively D, Kustas, W. A within-season approach for
8 detecting early growth stages in corn and soybean using high temporal and spatial
9 resolution imagery. *Remote Sensing of Environment*, 2020, 242, 111752.
- 10 50. Viana S, Girao R, Bendahan A, Freitas V. Análise visual de índices de vegetação utilizando
11 imagens RGB para classificação de áreas de pastagens com presença de plantas invasoras.
12 *Semana Nacional de Ciência e Tecnologia*. 2020;15:70-74. Português.
- 13 51. Yang Y, Wei X, Wang J, Zhou G, Wang J, Jiang Z, et al. Prediction of Seedling Oilseed
14 Rape Crop Phenotype by Drone-Derived Multimodal Data. *Remote*
15 *Sensing*. 2023;15:3951-3971.
- 16 52. Vergara-Díaz O, Zaman-Allah M, Hornero A, Zarco-Tejada P, Prasanna B, Cairns J. A
17 novel remote sensing approach for prediction of maize yield under different conditions of
18 nitrogen fertilization. *Frontiers in Plant Science*. 2016;7:666-679.
- 19 53. Zhou J, Zhou J, Ye H, Ali M, Nguyen H, Chen P. Classification of soybean leaf wilting
20 due to drought stress using UAV-based imagery. *Computers and Electronics in*
21 *Agriculture*. 2020;175:105576.
- 22 54. Gracia-Romer A, Kefauver S, Vergara-Díaz O, Zaman-Allah M, Prasanna B, Cairns J, et
23 al. Comparative performance of ground vs. aerially assessed RGB and multispectral
24 indexes for early-growth evaluation of maize performance under phosphorus fertilization.
25 *Frontiers in Plant Science*. 2017;8:1-13.
- 26 55. Qin J, Hu T, Yuan J, Liu Q, Wang W, Liu J, et al. Reconhecimento do estágio fenológico
27 do arroz baseado em aprendizagem profunda. *Deep-Learning-Based Rice Phenological*
28 *Stage Recognition*. *Remote Sensing*. 2023;15:2891. Português.
- 29 56. Shafian A, Rajan N, Schenel R, Bagavathiannan M, Valasek J, Shi Y, et al. Unmanned
30 aerial systems-based remote sensing for monitoring sorghum growth and development.
31 *Plos One*. 2018;13.

CAPÍTULO 2. RECONHECIMENTO DOS ESTÁDIOS FENOLÓGICOS DA SOJA A PARTIR DE ÍNDICES DE VEGETAÇÃO ANALISADOS VIA *RANDOM FOREST*

Airton Andrade da Silva ¹ ¶*, Francisco Charles dos Santos Silva ² ¶*

¹ Departamento de Agronomia, Universidade Estadual do Maranhão, Balsas, MA, Brasil;

² Departamento de Agronomia, Universidade Estadual do Maranhão, Balsas, MA, Brasil;

*Correspondência do autor.

E-mail: silvaxtp@gmail.com

E-mail: franciscocharlessilva@professor.uema.br

¶Esses autores contribuíram igualmente para esse trabalho.

Escrita e edição, Airton Andrade da Silva (AAS), Pesquisa em campo, AAS e Francisco Charles dos Santos Silva (FCSS); Análise estatística, AAS e FCSS; Correções, FCSS.

Resumo

A identificação da fenologia em grandes áreas é um trabalho oneroso e que demanda tempo, com isso o uso de Índices de Vegetação (IVs), obtidos a partir de imagens de sensores orbitais, possuem potencial para sanar essa problemática. Assim, teve-se como objetivo identificar os índices de vegetação mais eficiente na distinção dos estádios fenológicos da cultura da soja, utilizando imagens coletadas por sistemas sensores com diferentes resoluções espaciais analisados via *Random Forest* (RF). A pesquisa foi realizada em Balsas/MA em delineamento de blocos casualizados com avaliações semanalmente da fenologia. Os produtos com os dados espectrais foram obtidos dos sensores MSI e WFI embarcados nos satélites Sentinel-2 e Amazônia-1, respectivamente. As imagens foram processadas no *software* Qgis para a obtenção dos valores dos pixels dos blocos após o cálculo dos IVs NDVI, NDWI, SAVI, VARI, IV GREEN e GLI. Os dados foram submetidos a análise de variância e ao algoritmo de aprendizado de máquinas RF. A análise de variância possibilitou observar que não houve diferença significativa dentro da área durante as avaliações, mas houve diferença entre os estádios fenológicos. Para o sistema-sensor Amazônia-1 os índices com melhores classificações corretas foram SAVI e GLI, e para o sistema-sensor Sentinel-2 os índices com melhores classificações corretas foram o NDWI e IVgreen. O grupo de índices NIR obteve melhores classificações corretas em relação ao grupo RGB para o sistema-sensor Sentinel-2 e o grupo de índices RGB obteve melhores classificações corretas em relação ao grupo NIR para o sistema-sensor Amazonia-1. A avaliação conjunta dos índices avaliados apresentou melhor classificação correta para o sistema-sensor Sentinel-2 em relação ao sistema-sensor Amazonia-1. Portanto, os índices de vegetação de forma individual e em grupos RGB e NIR não são eficientes na identificação dos estádios fenológicos, o uso dos índices de forma conjunta utilizando o algoritmo Floresta Aleatória é a maneira mais eficiente para identificar os estádios fenológicos, e o sistema-sensor Sentinel-2 é superior ao sistema-sensor Amazonia-1 na identificação dos estádios fenológicos da soja.

Abstract

Identifying phenology in large areas is an expensive and time-consuming task, so the use of Vegetation Indices (VIs), obtained from images from orbital sensors, has the potential to

solve this problem. Thus, the objective was to identify the most efficient vegetation indices in distinguishing the phenological stages of soybean crops, using images collected by sensor systems with different spatial resolutions and Random Forest algorithm. The research was carried out in Balsas/MA in a randomized block design with weekly assessments of phenology and Leaf Area Index (LAI). The spectral data products were obtained from the MSI and WFI sensors onboard the Sentinel-2 and Amazônia-1 satellites, respectively. The images were processed in the Qgis software to obtain the block pixel values and subsequent calculation of the IVs NDVI, NDWI, SAVI, VARI, IV GREEN and GLI. The data was subjected to analysis of variance and the Random Forest machine learning algorithm. The analysis of variance made it possible to observe that there was no significant difference within the area during the evaluations, but there was a difference between the phenological stages. For the Amazônia-1 sensor system, the indices with the best correct classifications were SAVI and GLI, and for the Sentinel-2 sensor system, the indices with the best correct classifications were NDWI and IVgreen. The NIR index group obtained better correct classifications in relation to the RGB group for the Sentinel-2 sensor system and the RGB index group obtained better correct classifications in relation to the NIR group for the sensor system Amazonia-1. The joint evaluation of the evaluated indices showed a better correct classification for the Sentinel-2 sensor system in relation to the Amazonia-1 sensor system. Therefore, the conclusions were that vegetation indices individually and in RGB and NIR groups are not efficient in identifying phenological stages, using the indices jointly using the Random Forest algorithm is the most efficient way to identify the phenological stages, and the Sentinel-2 sensor system is superior to the Amazonia-1 sensor system in identifying soybean phenological stages.

Introdução

A soja [*Glycine max* (L.) Merrill] é uma cultura de elevada importância econômica, social e nutricional[1]. Assim, pesquisas que visem agregar tecnologias e auxiliar na tomada de decisão das práticas agrícolas a partir da interpretação e a integração de informações, como os Estádios Fenológicos obtidos por Índices de Vegetação (IV), são essenciais para garantir o melhor manejo na cultura [2, 3].

A fenologia da soja é uma variável importante a ser considerada nas tomadas de decisões durante a conjunção da lavoura [5, 6, 7]. Porém, a identificação do estágio fonológico correto em grandes áreas e com datas de semeadura distintas torna-se um trabalho oneroso, que demanda tempo e conhecimento técnico. Assim, os IVs podem ser ferramentas utilizadas para monitorar a fenologia da soja durante o desenvolvimento das plantas, a partir da estimativa da quantidade de energia eletromagnética refletida pelo dossel da cultura [8]. Mas, essas informações espectrais são complexas e geram uma grande quantidade de dados, além disso muitas das relações existentes entre os estádios fenológicos e os índices de vegetação são de natureza não linear, o que torna o uso de técnicas de *Machine Learning* (ML) uma excelente alternativa ao processamento de dados espectrais, como por exemplo os algoritmos de Florestas Aleatórias ou *Random Forest* (RF).

O aprendizado de máquina descreve a capacidade dos sistemas de aprender com dados de treinamento específicos de problemas para automatizar o processo de construção de modelos analíticos e resolver tarefas associadas, auxiliando no processamento de grande conjunto de dados [9]. Já a Floresta Aleatória é uma ferramenta de aprendizado de máquina capaz de levar em conta a correlação e interação entre os dados, onde possui o princípio de agregar uma coleção de árvores de decisão aleatórias com o objetivo de reunir um conjunto de preditores, árvores individuais que são perturbadas aleatoriamente, o que resulta em uma exploração mais extensa do espaço de todos os possíveis preditores de árvores, o que, na prática, resulta em melhor desempenho preditivo, sendo altamente adaptável a grandes conjuntos de dados [10].

Diversos estudos demonstram a eficiência da RF na identificação da fenologia das culturas do arroz com precisão de 0,99454 [11], soja, milho, canola e trigo, com precisão de 0,85, 0,9, 0,93 e 0,91, respectivamente [12] e na cultura da soja que teve predição de 0,7, 0,5 e 0,6 no índice de área foliar para os estádios de floração, enchimento de grãos e maturação, respectivamente [13].

Porém, são escassos os estudos que buscam comparar a eficiência de diferentes índices de vegetação na identificação dos diferentes estádios fenológicos na soja usando algoritmos de Florestas Aleatórias. Além de avaliar diferentes sistemas-sensores com diferentes resoluções espaciais, pois os trabalhos utilizam apenas uma fonte de dados. Dessa forma, o presente estudo teve-se como objetivo identificar os índices de vegetação mais eficiente na distinção dos estádios fenológicos da cultura da soja, utilizando imagens coletadas por sistemas sensores com diferentes resoluções espaciais analisados via *Random Forest* (RF).

Metodologia

Caracterização do local de estudo

A presente pesquisa foi desenvolvida entre abril e julho de 2022, em uma área de produção comercial de sementes de soja, com 80 ha, localizada a 30 Km do município de Balsas, MA, Brasil (Fig 1), onde o cultivar de soja TMG2383 foi conduzida sob irrigação por pivô central. O local está a 7° 31' 59" Sul, 46° 2' 6" Oeste, 243 metros de altitude e apresenta clima tropical chuvoso (Aw) e temperatura média de 27,1 °C, segundo a classificação climática de Köppen. A precipitação pluviométrica média anual é de 1175 mm, com maiores precipitações nos meses de novembro a abril, quando concentram 85% do total [14].




Fig. 1. Localização da área de estudo.

O solo da área experimental foi classificado como Latossolo Vermelho. Os dados meteorológicos de temperatura, precipitação e nebulosidade referentes ao período do estudo (Fig 2) foram obtidos pela estação meteorológica do Instituto Nacional de Meteorologia (INMET) presente na região do estudo.




Fig 2. Dados de Temperatura, Precipitação total e Nebulosidade durante os meses de execução do experimento em Balsas no ano 2022 [15].

Condução do experimento

O experimento foi instalado em delineamento de blocos casualizados, com quatro repetições. Cada repetição foi constituída de uma área de 5 metros de raio, para os produtos Sentinel-2, e 30 metros de raio, para os produtos Amazonia-1, cujos centros foram demarcados com um receptor Global Positioning System (GPS) de navegação.

Após a germinação da soja, foi realizado visualmente o monitoramento semanal da fenologia das plantas, de acordo com [16] (Tabela 1).

Tabela 1. Estádios Fenológicos da soja [16].

ESTÁDIO	DESCRIÇÃO
V1	Um par de folhas unifolioladas (ou um nó);
V2	Primeiro trifólio completamente desenvolvido (ou dois nós);
V3	Dois trifólios completamente desenvolvidos (ou três nós);
Vn	Estádios vegetativos até chegas ao reprodutivo a partir da emissão do primeiro botão floral;
R1	Uma flor aberta em qualquer nó na haste principal;
R2	Uma flor aberta em um dos dois nós superiores na haste principal com folha completamente desenvolvida;
R3	Vagem de 0,5 cm a 2,0 cm em um dos quatro nós superiores na haste principal;
R4	Vagem completamente desenvolvida (> 2,0 cm) em um dos quatro nós superiores na haste principal;
R5.1, R5.2, R5.3, R5.4 e R5.5	Início do enchimento de grãos (<10% até 100% de granação) em um dos quatro nós superiores da haste principal;
R6	Grão cheio ou completo em um dos quatro nós superiores na haste principal;
R7	Início da maturação. Uma vagem com coloração de madura na haste principal;
R8	Maturação Plena (colheita). Mais de 95% das vagens com coloração de madura.

Imagens coletadas pelo sensor *Multispectral Imager* (MSI), embarcado no satélite Sentinel-2, foram utilizadas como fonte de dados de reflectância, as quais foram obtidas do catálogo de imagens do Centro de Acesso Aberto *Copernicus* (<https://scihub.copernicus.eu/dhus/#/home>), em nível de processamento L2A. As imagens L2A possuíam correção para nuvens e sombras de nuvens, espessura óptica de aerossol, vapor de água, reflectância de superfície ortorectificada com precisão de registro multiespectral, e multitemporal de subpixel. O sensor disponibilizou produtos com resolução temporal de 5 dias, resolução espacial, que varia de 10 m a 65 m, resolução radiométrica de 10 bits e resolução espectral de 13 bandas, porém, no presente estudo, foram utilizadas apenas as bandas com resolução espacial de 10 metros (Tabela 2).

Tabela 2. Especificações técnicas do sensor MSI embarcado no satélite Sentinel-2 e do sensor WFI embarcado no satélite Amazônia-2.

Satélite	Resolução Temporal	Resolução Espectral (μm)	Resolução Radiométrica	Resolução Espacial
Sentinel-2	5 dias	Azul (0,49-0,56) Verde (0,56-0,665) Vermelho (0,665-0,842) Infravermelho Próximo (0,842-0,865)	10 bits	10 m
Amazônia-1	5 dias	Azul (0,45-0,52) Verde (0,52-0,59) Vermelho (0,63-0,69) Infravermelho Próximo (0,77-0,89)	10 bits	~65 m

Imagens do sensor orbital WFI (*Wide Field Imager*), embarcado no satélite Amazônia-1, também foram utilizadas como fonte de dados de reflectância, as quais foram obtidas do catálogo de imagens do INPE – Instituto Nacional de Pesquisas Espaciais (<http://www2.dgi.inpe.br/catalogo/explore>). O sensor disponibilizou produtos com resolução de acordo com a Tabela 2.

A escolha de ambos satélites foi realizada pela resolução temporal de 5 dias, o que permite melhor monitoramento da fenologia no decorrer do ciclo da cultura, e resolução espacial de 10 e 64 m, possibilitando a comparação da qualidade dos dados. Pois, de acordo com Bariani [17] o monitoramento da fenologia, por meio de sensores orbitais, deve possuir a maior quantidade de dados durante o ciclo, favorecendo o acompanhamento dos diferentes estádios da cultura.

A resolução temporal dos sensores proporcionou a coleta de 14 imagens para o satélite Sentinel-2 e 11 imagens para o satélite Amazônia-1, ao longo do ciclo da cultura, o que possibilitou a obtenção de informações espectrais para os estádios fenológicos de V3 a R8 (Fig 3). O critério para a seleção de imagens seguiu a disponibilidade para *download* dos respectivos catálogos de imagens e que não apresentassem cobertura total de nuvens na área de estudo.




Fig 3. Aspecto morfológico da soja nos diferentes estádios fenológicos em que foram obtidas informações espectrais pelos satélites Sentinel-2 e Amazônia-1.

Adaptado Oliveira Júnior et al. [16].

Processamento das imagens

As imagens foram processadas no *software Qgis* versão 3.26.3 [18] usando como sistema de coordenadas o *Datum* Sirgas 2000 UTM Zona 23S e submetidas as equações dos IVs da Tabela 03.

1 **Tabela 3 - Índices de vegetação.**

Tipo	Índice de vegetação	Nome	Equação	Referências
NIR	NDVI	Índice de Vegetação por Diferenciação Normalizada	$(B8-B4)/(B8+B4)$	[19]
	NDWI	Índice de Água por Diferenciação Normalizada	$(B3-B8)/(B3+B8)$	[20]
	SAVI	Índice de Vegetação Ajustado ao Solo	$(1+L)*[(B8-B4) \div (B8+B4+L)]$	[21]
RGB	VARI	Índice de Resistência Atmosférica Visível	$(B3-B4)/(B3+B4-B2)$	[22]
	GLI	Índice Folha Verde	$(2*B3-B4-B2) / (2*B3+B4+B2)$	[23]
	IV GREEN	Índices de resistência atmosférica Verde Visível	$(B3-B4)/(B3+B4)$	[22]

2 B4: refletância no vermelho, B8: refletância no infravermelho próximo, B3: refletância no verde; B2: refletância
 3 no azul; L = fator de ajuste podendo variar de 0 a 1.

5 Estatística

6
 7 Os dados dos índices de vegetação foram submetidos a análise de variância. Os índices
 8 que apresentaram diferença significativa foram submetidos a análise de RF.

9 À medida que o crescimento das culturas avança, a geometria (tamanho, forma e
 10 orientação), composição de pigmentos e o conteúdo de água dos múltiplos órgãos da planta
 11 mudam e, como tal, o desenvolvimento fenológico é multifacetado e complexo. Para resolver
 12 a não linearidade e a complexidade no problema da identificação dos estádios fenológicos, este
 13 estudo investiga uma abordagem de aprendizagem em conjunto, nomeadamente um algoritmo
 14 *Random Forest* (RF), que combina múltiplas árvores de decisão. Uma única árvore de decisão
 15 pode ser usada, mas resulta em generalização de dados e maior variação na previsão, sendo esta
 16 variação reduzida pelo algoritmo RF que adiciona aleatoriedade nos dados e calcula a média
 17 das saídas de múltiplas árvores de decisão, resultando em previsões mais precisas e estáveis
 18 (Fig 4).




Fig 4. Esquema de funcionamento do algoritmo de Floresta Aleatória (*Random Forest*).

O conceito principal do RF é que uma composição de classificadores fracos pode dar bons resultados tanto para problemas de classificação quanto para problemas de regressão, sendo proposto por Breiman em 1996 [24]. Nesse estudo, a RF foi utilizada para problemas de classificação dos 14 estádios fenológicos da soja obtidos pelo sistema-sensor Sentinel-2 e os 11 estádios fenológicos obtidos pelo sistema-sensor Amazonia-1, a partir dos 6 índices de vegetação, sendo 3 classificados como infravermelho (NIR), devido possuir o comprimento de onda do infravermelho próximo no cálculo dos índices, e 3 RGB (Red, Green e Blue), devido possuir apenas comprimentos de ondas do espectro visível, ou seja, azul, verde e vermelho.

A classificação foi realizada de forma visual em relação ao valor da correlação entre as árvores, levando em consideração as variáveis, índices de vegetação e estádios fenológicos, de modo que valores até 87,5% de predição correta foram classificados como uma predição adequada para os estádios fenológicos da soja. Para a análise de variância foi utilizado o programa Genes [25] e para realizar a análise *Random Forest* foi utilizado o *Software Waikato Environment for Knowledge Analysis (Weka)* [26].

Resumo da metodologia

Um resumo da metodologia utilizada na presente pesquisa está ilustrado na Fig 5.




Fig 5. Fluxograma da metodologia da presente pesquisa.

Resultados e Discussão

A análise de variância para os Índices de Vegetação (IVs) de ambos os sistema-sensores, possibilitou observar que não houve diferença significativa dentro da área durante a avaliação de cada estágio, mas houve diferença entre os estádios fenológicos durante o ciclo da cultura, demonstrando que todos os índices apresentam variações à medida que as plantas se desenvolviam (Tabela 4).

Tabela 4. Análise de variância para os dados dos Sistemas-sensores estudados.

Índices de Vegetação	----- Quadrados Médios -----			
	----- Sentinel-2 -----		----- Amazonia-1 -----	
	Repetição	Estádios	Repetição	Estádios
NDVI	0,006 ^{ns}	0,1013 ^{**}	0,0186 ^{ns}	0,0950 ^{**}
NDWI	0,0007 ^{ns}	0,0812 ^{**}	0,0035 ^{ns}	0,1108 ^{**}
SAVI	0,0023 ^{ns}	0,1748 ^{**}	0,0037 ^{ns}	0,1900 ^{**}
VARI	0,0004 ^{ns}	0,0286 ^{**}	0,0011 ^{ns}	0,2577 ^{**}
GLI	0,0101 ^{ns}	0,0715 ^{**}	0,0004 ^{ns}	0,2156 ^{**}
IV GREEN	0,0001 ^{ns}	0,0087 ^{**}	0,0073 ^{ns}	0,0382 ^{**}

^{**} e ^{*} significativos a 1 e 5% de probabilidade; respectivamente; pelo teste F

^{ns} não-significativo; pelo teste F

Vários autores relatam diferença entre os estádios fenológicos da soja ao utilizarem IV para seu monitoramento, sendo esta diferença caracterizada por baixos valores no início do ciclo, cresce gradualmente até um máximo de biomassa e decresce com o término do ciclo da cultura [27, 28, 29, 30, 31, 32, 33, 34].

De acordo com Panzoni, Shimabukuro e Kuplich [35] e Gao e Zangh [36] o comportamento espectral na soja pode ser descrito com o início do processo de transmitância da energia eletromagnética, absorção da luz visível das bandas azul, vermelho e verde e reflectância do infravermelho próximo, onde esse padrão se estende até o estágio reprodutivo a partir da parada do desenvolvimento de folhas e diminuição da alteração na morfologia. O comportamento espectral altera no início do aparecimento das vagens, onde ocorre intenso fluxo de seiva elaborada para o enchimento dos grãos nas vagens e ocorrer a oxidação dos pigmentos fotossintéticos, como a clorofila, o que resulta na menor absorção de luz visível e maior absorção do infravermelho próximo até a completa morte do tecido vegetal [35, 36].

Os índices NDVI, NDWI e SAVI em ambos os sistemas-sensor, e o índice VARI, no sistema-sensor Amazonia-1, apresentaram maior variabilidade de dados, demonstrando que esses índices apresentaram maior sensibilidade às mudanças nos estádios fenológicos da cultura, como pode ser observado na dispersão (Fig 6). Tais observações são relevantes, visto que índices diferentes e com sensibilidades distintas à variação no crescimento e desenvolvimento da planta também podem apresentar eficiência na identificação dos estádios fenológicos da soja.




Fig 6. Boxplot representando a dispersão dos dados dos índices de vegetação para os sistemas-sensores Sentinel-2 (A) e Amazonia-1 (B).

Vários autores relatam a eficiência de diferentes IV na identificação da fenologia da soja [37, 28]; milho e soja [34]; trigo, milho e [29, 30]; milho e soja [31]; no arroz [32] e no milho [33].

As distintas sensibilidades ao monitoramento da fenologia da soja a partir de diferentes IVs se dá pela classificação dos índices em RGB e NIR, sendo categorizados devido aos comprimentos de ondas que participam na equação de cada índice.

Os índices VARI, IV GREEN e GLI, como possuem na sua composição apenas as bandas do azul, verde e vermelho, são classificados como índices RGB. Esses consideram comprimentos de ondas do espectro visível que se relacionam apenas com os pigmentos da folha (clorofila, carotenoides, antocianinas e xantofilas) que são os responsáveis por absorver (80-90%) da luz visível com pico de 0,55 μm , e refletir 10-20% da luz visível, principalmente a banda verde [35].

Já os índices NDVI, NDWI e SAVI possuem informações da faixa do infravermelho-próximo (NIR) na sua composição, sendo classificados como índices NIR. Essa faixa espectral apresenta bastante sensibilidade à variação biomassa da vegetação e consequentemente à variação de crescimento e desenvolvimento das plantas [35].

A análise de variância (Tabela 6) e o Boxplot (Fig 6) demonstraram que os IV podem ser eficientes na distinção dos estádios fenológicos da soja, sendo assim possível, quantificar a eficiência, para cada índice de vegetação, por meio da porcentagem classificações corretas realizadas pelo algoritmo *Random Forest* (Fig 7).




Fig 7. Classificação correta dos IV para a estimativa dos estádios fenológicos da soja para os diferentes sistemas-sensores.

Para o sistema-sensor Sentinel-2 os índices com melhores classificações corretas foram o NDWI e NDVI (Fig 7), sendo o índice NDVI o que apresentou maior variabilidade de dados (Tabela 4) na análise de variância para esse sistema-sensor, demonstrando maior sensibilidade às mudanças nos estádios fenológicos da cultura. De acordo com Mc Feeters [20], o índice NDWI realça características de águas abertas e aumenta sua presença em imagens digitais, pois utiliza radiação infravermelha próxima refletida e luz verde visível para aumentar a presença de tais características, ao mesmo tempo que elimina a presença de características do solo. Já o NDVI é a normalização da relação das bandas do vermelho e infravermelho próximo, sendo a última banda associada aos espaços intracelulares da vegetação, o que permite realizar o monitoramento da fenologia da soja, resultando em valores próximos a 1 no máximo crescimento da cultura e decréscimo dos valores durante o estresse oxidativo dos pigmentos foliares relacionados ao comprimento de onda do vermelho [19].

Por sua vez, para o sistema-sensor Amazônia-1 os índices com melhores classificações corretas foram SAVI e GLI (Fig 7), sendo o índice GLI o que apresentou maior variabilidade de dados (Tabela 4) na análise de variância para esse sistema-sensor, demonstrando maior sensibilidade às mudanças nos estádios fenológicos da cultura. De acordo com Louhaichi, Borman e Johnson [21], o índice GLI avalia a diferença normalizada das refletâncias das faixas espectrais do azul, verde e vermelho e gera uma imagem com amplitude de -1 a 1, onde os valores negativos representam áreas de solo e valores positivos, da vegetação. Este índice é parecido ao SAVI, visto que este é o aprimoramento do NDVI, porém com a adição de um fator de correção para exclusão da influência do solo [23].

Ainda na Fig 7 foi observado que individualmente nenhum dos índices estudados, independente do sistema-sensor, apresentou 100% de eficiência na classificação correta dos estádios fenológicos. Demonstrando que, independentemente da resolução espacial da imagem os índices de vegetação desse estudo, quando analisados individualmente, seja RGB ou com a banda NIR, não são plenamente eficientes na identificação correta de estádios fenológicos de soja.

Afim de averiguar a capacidade dos índices em identificar os estádios fenológicos quando seus efeitos são considerados simultaneamente, os índices RGB e os baseados na banda NIR foram submetidos ao algoritmo de *Random Forest*.

Para o sistema-sensor Sentinel-2, os índices NIR (Fig 8) foram mais eficientes em relação ao grupo RGB (Fig 9), alcançando máxima eficácia na identificação dos estádios V5, dos estádios reprodutivos iniciais (R1 e R2) e estádios que marcam o início e final do

enchimento de grãos (R5.1 e R5.5). Por sua vez o grupo RGB que só apresentou classificação 100% correta no estágio R1.

V3	V5	V8	R1	R2	R3	R4	R5-1	R5-2	R5-4	R5-5	R6	R7	R8	
62,5	25	0	0	12,5	0	0	0	0	0	0	0	0	0	V3
0	100	0	0	0	0	0	0	0	0	0	0	0	0	V5
0	0	62,5	25	0	0	0	0	0	0	0	0	0	12,5	V8
0	0	0	100	0	0	0	0	0	0	0	0	0	0	R1
0	12,5	0	0	87,5	0	0	0	0	0	0	0	0	0	R2
0	0	0	0	0	25	0	0	25	0	12,5	12,5	25	0	R3
0	0	0	0	0	12,5	50	0	0	0	0	12,5	25	0	R4
0	0	0	0	0	0	0	100	0	0	0	0	0	0	R5-1
0	0	0	0	0	12,5	12,5	12,5	50	0	0	12,5	0	0	R5-2
0	0	0	0	0	12,5	0	0	0	62,5	0	25	0	0	R5-4
0	0	0	0	0	0	0	0	0	0	87,5	12,5	0	0	R5-5
0	0	0	0	0	12,5	12,5	0	0	25	12,5	37,5	0	0	R6
0	0	0	0	0	12,5	12,5	0	0	0	0	25	50	0	R7
0	0	25	0	0	0	0	0	0	0	0	0	0	75	R8

Fig 8. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs NIR para o sistema-sensor Sentinel-2.

V3	V5	V8	R1	R2	R3	R4	R5-1	R5-2	R5-4	R5-5	R6	R7	R8	
62,5	25	12,5	0	0	0	0	0	0	0	0	0	0	0	V3
12,5	87,5	0	0	0	0	0	0	0	0	0	0	0	0	V5
25	0	75	0	0	0	0	0	0	0	0	0	0	0	V8
0	0	0	100	0	0	0	0	0	0	0	0	0	0	R1
0	0	0	0	87,5	0	0	0	12,5	0	0	0	0	0	R2
0	0	0	0	0	37,5	0	12,5	25	12,5	0	0	0	12,5	R3
0	0	0	0	12,5	0	62,5	0	25	0	0	0	0	0	R4
0	0	0	0	0	0	0	87,5	12,5	0	0	0	0	0	R5-1
0	0	0	0	0	0	12,5	12,5	62,5	12,5	0	0	0	0	R5-2
0	0	0	0	0	12,5	0	12,5	0	50	25	0	0	0	R5-4
0	0	0	0	0	0	0	0	0	0	75	0	25	0	R5-5
0	0	0	0	0	0	0	0	0	0	12,5	50	37,5	0	R6
0	0	0	0	0	0	12,5	0	0	0	0	37,5	50	0	R7
0	0	0	12,5	0	0	12,5	0	0	0	0	0	0	75	R8

Fig 9. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs RGB para o sistema-sensor Sentinel-2.

Em relação aos índices RGB, o grupo de índices NIR, para o sistema-sensor Sentinel-2, se mostrou mais eficiente na identificação correta dos estádios fenológicos. Isso se deve ao fato de que os índices desse grupo leva em consideração no seu cálculo a banda do infravermelho próximo, que de acordo Panzoni, Shimabukuro e Kuplich [35], este comprimento de onda é absorvido na proporção de 50-60% por estruturas celulares das folhas, como a epiderme, parênquima paliádico e lacunoso, sistema vascular e epiderme inferior, resultando em

adequada eficiência para acompanhar o desenvolvimento e crescimento da cultura ao passar dos estádios fenológicos.

Por sua vez, para o sistema-sensor Amazonia-1, o grupo de índices RGB (Fig 11) foi levemente superior aos índices NIR na identificação correta dos estádios fenológicos (Fig 10), obtendo máxima eficácia na identificação dos R2 e R4.

V3	V5	V8	R1	R2	R4	R5-1	R5-2	R5-4	R5-5	R8	
75	12,5	0	0	0	0	0	0	0	0	12,5	V3
12,5	62,5	25	0	0	0	0	0	0	0	0	V5
12,5	12,5	12,5	37,5	12,5	0	0	0	0	0	12,5	V8
0	0	37,5	62,5	0	0	0	0	0	0	0	R1
0	0	25	0	62,5	0	0	0	0	0	12,5	R2
0	0	0	0	0	75	0	0	0	12,5	12,5	R4
0	0	0	0	0	0	100	0	0	0	0	R5-1
0	0	0	0	0	0	0	50	12,5	37,5	0	R5-2
0	0	0	0	0	25	12,5	37,5	12,5	12,5	0	R5-4
0	0	0	0	0	0	25	12,5	25	37,5	0	R5-5
25	0	25	0	0	25	0	0	0	0	25	R8

Fig 10. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs NIR para o sistema-sensor Amazonia-1.

V3	V5	V8	R1	R2	R4	R5-1	R5-2	R5-4	R5-5	R8	
50	12,5	12,5	0	0	0	12,5	0	12,5	0	0	V3
12,5	62,5	12,5	0	0	0	12,5	0	0	0	0	V5
25	0	62,5	0	0	0	12,5	0	0	0	0	V8
0	0	12,5	62,5	0	0	0	0	12,5	0	12,5	R1
0	0	0	0	100	0	0	0	0	0	0	R2
0	0	0	0	0	100	0	0	0	0	0	R4
12,5	0	25	0	0	37,5	12,5	12,5	0	0	0	R5-1
0	0	0	0	0	0	12,5	25	50	12,5	0	R5-2
0	0	0	25	0	0	12,5	12,5	25	25	0	R5-4
0	12,5	0	0	0	0	0	25	25	37,5	0	R5-5
0	12,5	0	0	12,5	0	0	0	0	0	75	R8

Fig 11. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta do grupo de IVs RGB para o sistema-sensor Amazonia-1.

O grupo de índices RGB para o sistema-sensor Amazonia-1 apresentou melhor classificação correta nos estádios reprodutivos devido estes estarem correlacionados aos comprimentos de onda do visível que possuem interação apenas com os pigmentos fotossintéticos, sendo nesses estádios o máximo acúmulo de pigmentos, principalmente devido ao máximo crescimento e desenvolvimento ocorrido nesses estádios. De acordo com Gao e Zangh [36], o comportamento espectral da soja altera no início do aparecimento das vagens devido ao intenso fluxo de seiva elaborada para o enchimento dos grãos nas vagens e ocorrer a oxidação dos pigmentos fotossintéticos, como a clorofila, o que resulta na menor absorção de luz visível, possibilitando a melhor diferenciação desses estádios, por índices RGB, devido ao

máximo acúmulo de pigmentos em estádios reprodutivos iniciais e menor diferenciação devido a degradação progressiva dos pigmentos em estádios reprodutivos finais.

Como observado, quando analisados em grupos, os índices não apresentaram classificações corretas para todos os estádios, principalmente para os finais, sendo necessário realizar a avaliação conjunta de todos os índices, independente do grupo a qual cada um pertence.

Na avaliação simultânea dos índices analisados o sistema-sensor Sentinel-2 se apresentou mais eficiente (Fig 12) em relação ao sistema-sensor Amazonia-1 (Fig 13), sendo preciso na identificação dos estádios vegetativos finais (V5 e V8), estádios reprodutivos iniciais (R1 e R2), início de enchimento de grãos (R5.1) e maturação fisiológica (R8). Já o sistema-sensor Amazonia-1 foi eficaz apenas na identificação do estágio vegetativo inicial (V3), estágio reprodutivo inicial (R2), formação completa das vagens (R4), início do enchimento dos grãos (R5.1) e maturação fisiológica (R8).

V3	V5	V8	R1	R2	R3	R4	R5-1	R5-2	R5-4	R5-5	R6	R7	R8	
75	12,5	0	0	12,5	0	0	0	0	0	0	0	0	0	V3
0	100	0	0	0	0	0	0	0	0	0	0	0	0	V5
0	0	100	0	0	0	0	0	0	0	0	0	0	0	V8
0	0	0	100	0	0	0	0	0	0	0	0	0	0	R1
0	0	0	0	100	0	0	0	0	0	0	0	0	0	R2
0	0	0	0	0	25	25	0	37,5	0	0	12,5	0	0	R3
0	0	0	0	0	12,5	75	0	12,5	0	0	0	0	0	R4
0	0	0	0	0	0	0	100	0	0	0	0	0	0	R5-1
0	0	0	0	0	25	0	12,5	62,5	0	0	0	0	0	R5-2
0	0	0	0	0	12,5	0	0	0	62,5	12,5	12,5	0	0	R5-4
0	0	0	0	0	0	0	0	0	0	75	12,5	12,5	0	R5-5
0	0	0	0	0	0	0	0	0	12,5	25	62,5	0	0	R6
0	0	0	0	0	0	12,5	0	0	0	0	25	62,5	0	R7
0	0	0	0	0	0	0	0	0	0	0	0	0	100	R8

Fig 12. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta em conjunto dos grupos de IVs para o sistema-sensor Sentinel-2.

V3	V5	V8	R1	R2	R4	R5-1	R5-2	R5-4	R5-5	R8	
87,5	12,5	0	0	0	0	0	0	0	0	0	V3
25	50	25	0	0	0	0	0	0	0	0	V5
12,5	25	50	12,5	0	0	0	0	0	0	0	V8
0	0	12,5	75	0	0	0	0	0	0	12,5	R1
0	0	0	0	100	0	0	0	0	0	0	R2
0	0	12,5	0	0	87,5	0	0	0	0	0	R4
0	0	0	0	0	0	100	0	0	0	0	R5-1
0	0	0	0	0	0	12,5	62,5	12,5	12,5	0	R5-2
0	0	0	0	0	0	25	25	12,5	37,5	0	R5-4
0	0	0	0	0	0	0	12,5	37,5	50	0	R5-5
0	0	0	12,5	0	0	0	0	0	0	87,5	R8

Fig 13. Matriz de confusão contendo na diagonal principal a porcentagem da predição correta em conjunto dos grupos de IVs para o sistema-sensor Amazonia-1.

A superioridade do sistema-sensor Sentinel-2 possivelmente está associada à sua melhor resolução espacial, em comparação a do sistema-sensor Amazonia-1. Sishodia, Ray e Singh [37] relatam que a resolução espacial de um sensor é definida pelo tamanho do pixel que representa a área no solo, onde quanto menor for o tamanho real deste pixel, maior será a resolução espacial desta imagem, o que significa que maior será a capacidade de registrar alterações em objetos sensoriados, como a vegetação. Como também comprovado por Zheng et al. [38], onde observou, ao estudar a fenologia do milho e trigo, que a resolução espacial menor (10-20m) do satélite SPOT5 possibilitou a melhor detecção da fenologia dessas culturas em relação ao satélite MODIS com resolução espacial de 250m, alcançando precisão de 86,7% para o trigo e 90,2% para o milho.

Mesmo levando considerando os seis índices de vegetação simultaneamente, elevada porcentagem de classificações erradas foram observadas sobretudo nos estádios R5.2 a R6. Essas classificações erradas podem ser justificadas devido ao curto período de duração desses estádios e pouca modificação na morfologia da cultura (Fig 3), tornando difícil a classificação e classificando-os como outros estádios. Comportamento semelhante foi observado na cultura do arroz por [39].

Conclusões

Os índices de vegetação de forma individual e em grupos RGB e NIR não são eficientes na identificação dos estádios fenológicos da soja utilizando imagens orbitais.

O uso dos índices de forma conjunta utilizando o algoritmo *Radom Forest* é a maneira mais eficiente para identificar os estádios fenológicos da soja devido à natureza não linear do comportamento da cultura.

O sistema-sensor Sentinel-2 é superior ao sistema-sensor Amazonia-1 na identificação dos estádios fenológicos da soja.

Referências

1. Silva F, Borem A, Sedyama T, Câmara G. Soja: do plantio à colheita. 2ª edição. São Paulo: Oficina de Textos;2022.

2. Molin JP, Bazame H, Maldaner R, Corredo L, Martello M. Agricultura de precisão e as contribuições digitais para a gestão localizada das lavouras. *Revista Ciência Agronômica*. 2021;51. Português.
3. Monzon JP, Calvino P, Sadras V, Zubiaurri J, Andrade F. Precision agriculture based on crop physiological principles improves whole-farm yield and profit: A case study. *European Journal of Agronomy*. 2018;99:62-71.
4. Gava R, Frizzon J, Snyder R, Almeida B, Freitas P, Rezende R. Estratégias de manejo de déficit hídrico na irrigação da cultura da soja. *Revista Brasileira de Engenharia de Biosistemas*. 2016;10(3):305-315. Português.
5. Foloni J, Henning F, Mertz-Hernning L, Rodrigues R, Mellos L, Neumaier N. Manejo de acamamento de cultivares de soja com lactofem em diferentes ambientes de produção. VII Congresso Brasileiro da Soja, Goiania, Brasil, 2018. Português.
6. Ecco M, Backes J, Reuter R. Manejo de aplicação de boro no cultivo da soja. *Revista Científica Rural*. 2022;24:12-25. Português.
7. Drehmer RG, Lajus CR, Cericato A. Rendimento da soja submetida a adição de fungicida multissítio em diferentes estádios fenológicos. *Anuário Pesquisa e Extensão Unoesc São Miguel do Oeste*. 2018;3:18891-18891. Português.
8. Oliveira M, Queiroz T, Teixeira A, Moreira L, Leão R. Espectrometria de reflectância aplicada à análise das deficiências de nitrogênio e potássio em algodoeiro. *Revista Ciência Agronômica*. 2020;51(4). Português.
9. Janiesch D, Zschech P, Heinrich K. Aprendizado de máquina e aprendizado profundo. *Mercados Eletrônicos*. 2021; 31 (3).
10. Chen X, Ishwaran H. Florestas aleatórias para análise de dados genômicos. *Genômica*. 2012; 99 (6).
11. Sheng R, Huang Y, Chan P, Bhat S, Huang N. Rice Growth Stage Classification via RF-Based Machine Learning and Image Processing. *Agriculture*, 2022;12(12):2137.
12. Wang H, Magagi R, Goita K, Trudel M, McNairn H, Poderes J. Crop phenology retrieval via polarimetric SAR decomposition and Random Forest algorithm. *Remote Sensing of Environment*, 2019;231:111234.
13. Zhang Y, Yang Y, Zhang Q, Duan R, Liu J, Qin Y, et al. Toward multi-stage phenotyping of soybean with multimodal UAV sensor data: a comparison of machine learning approaches for leaf area index estimation. *Remote Sensing*, 2022;15(1):7.

- 1 14. Passos ML, Zambrzycki, GC, Pereira RS. Balanço hídrico climatológico e classificação
2 climática para o município de Balsas - MA. Revista Scientia Agraria. 2017;18:83-89.
3 Português.
- 4 15. Inmet, Instituto Nacional de Meteorologia do Brasil. Disponível em:
5 <https://portal.inmet.gov.br/>. Acessado em: 17 out. 2022.
- 6 16. Oliveira Júnior A, Castro C, Pereira L, Domingos C. Estádios fenológicos e marcha de
7 absorção de nutrientes da soja. Embrapa Milho e Sorgo-Boletim de Pesquisa e
8 Desenvolvimento (INFOTECA-E), 2016. Português.
- 9 17. Bariani C, Kerstini DS, Victoria NM, Carlesso R, Petry MT, Peripolli M. Monitoramento
10 da fenologia da soja irrigada usando perfis de série temporal de NDVI. III encontro
11 internacional INOVAGRI. 2015;1610-1618. Português.
- 12 18. QGIS. Geographi Information System QGIS. Disponível em: <http://www.qgis.org>. Acesso
13 em: 09 maio 2022.
- 14 19. Rouse JW, Haas RH, Schell JA, Deering DW, Harlan JC. Monitoring the vernal
15 advancement and retrogradation of natural vegetation. Greenbelt: National Aeronautics
16 and Space Administration. 1974:371.
- 17 20. Mc Feeters SK. The use of the Normalized Difference Water Index (NDWI) in the
18 delineation of open water features. International Journal of Remote Sensing.
19 1996;17:1425-1432.
- 20 21. Huete AR. A soil ajusted vegetation index (SAVI). Remote Sensing Environ. 1988;25.
- 21 22. Gitelson A, Kaufman Y, Stark R, Rundquist D. Novel algorithms for remote estimation of
22 vegetation fraction. Remote Sensing of Environment. 2002;80:76–87.
- 23 23. Louhaichi M, Borman M, Jhonson D. Spatially Located Platform and Aerial Photography
24 for Documentation of Grazing Impacts on Wheat. Geocarto International, 2001;16:65-70.
- 25 24. BREIMAN, L. Random forests. Machine learning, 2001;45:5-32.
- 26 25. Cruz CD. Genes Software - extended and integrated with the R, Matlab and Selegen. Acta
27 Scientiarum, 2016;38:547-552.
- 28 26. Garner SR. Weka: The waikato environment for knowledge analysis. In: Proceedings of
29 the New Zealand computer science research students conference, 1995;57–64.
- 30 27. Rodrigues C, Fontana D, Moraes O, Roberti D. NDVI e fluxo de CO2 em lavoura de soja
31 no Rio Grande do Sul. Revista Brasileira de Meteorologia. 2013;28:95-104. Português.
- 32 28. Estevam V, Reges N, Dos Santos M. Uso do índice ndvi para determinação fenológica da
33 cultura da soja. Revista uniaraguaia. 2023;18:106-115. Português.

29. Breaban LG, Stoleriu AP. Monitoring the crops phenology using time series sentinel 2 images. *Acta Geobalcanica (Skopje.Online)*. 2020;6:95-102.
30. Hatfield J, Pruger J. Value of Using Different Vegetative Indexes to Quantify Agricultural Crop Characteristics at Different Growth Stages under Varying Management Practices. *Remote Sens*. 2010;2:562-579.
31. Sakamoto T, Gitelson A, Nguy-Rbertson A, Arquebauer T, Wardlow B, Suyker A, et al. An Alternative Method Using Digital Cameras for Continuous Monitoring of Crop Status. *Agricultural and Forest Meteorology*. 2012;154:113-26.
32. Ge H, MA F, Li Z, Tan Z, Du C. Improved Accuracy of Phenological Detection in Rice Breeding by Using Ensemble Models of Machine Learning Based on UAV-RGB Imagery. *Remote Sensing*, 2021;11:2439.
33. Guo Y, Xiao Y, Hao F, Zhang X, Sol H, Beurs K, et al. Identifying crop phenology using maize height constructed from multi-sources images. *International Journal of Applied Earth Observation and Geoinformation*. 2022;115:103-121.
34. Bolton D, Friedl M. Forecasting Crop Yield Using Remotely Sensed Vegetation Indexes and Crop Phenology Metrics. *Agricultural and Forest Meteorology*. 2013;173:74-84.
35. Ponzoni FJ, Shimabukuro, Y. E.; Kuplich, T. M. Sensoriamento remoto da vegetação. 2. ed.; Oficina de Textos: São Paulo, Brasil, 2012;160. Português.
36. Gao F, Zhang X. Mapping crop phenology in near real-time using satellite remote sensing: Challenges and opportunities. *Journal of Remote Sensing*, 2021.
37. Neiverth W, Crusiol L, Carvalho J, Ferreira L, Rio A, Silbadelli R, et al. NDVI de estádios fenológicos da soja BRS 284 de crescimento indeterminado em casa de vegetação. *Embrapa Soja*. 2013:204-209. Português.
38. Sishodia RP, Ray RL, Singh SK. Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 2020;12(19):3136.
39. Zheng Y, Wu B, Zhang M, Zeng H. Crop phenology detection using high spatio-temporal resolution data fused from SPOT5 and MODIS products. *Sensors*. 2016;16(12):2099.
40. Qin J, Hu T, Yuan J, Liu Q, Wang W, Liu J, et al. Reconhecimento do estágio fenológico do arroz baseado em aprendizagem profunda. *Deep-Learning-Based Rice Phenological Stage Recognition. Remote Sensing*. 2023;15:2891. Português.

CAPÍTULO 3. ESTIMATIVA DA PRODUTIVIDADE DA SOJA A PARTIR DE ÍNDICES DE VEGETAÇÃO POR MEIO DE DIFERENTES SISTEMAS-SENSORES

Airton Andrade da Silva¹ ¶*, Francisco Charles dos Santos Silva² ¶*

¹ Departamento de Agronomia, Universidade Estadual do Maranhão, Balsas, MA, Brasil;

² Departamento de Agronomia, Universidade Estadual do Maranhão, Balsas, MA, Brasil;

*Correspondência do autor.

E-mail: silvaxtp@gmail.com

E-mail: franciscocharlessilva@professor.uema.br

¶Esses autores contribuíram igualmente para esse trabalho.

Escrita e edição, Airton Andrade da Silva (AAS), Pesquisa em campo, AAS e Francisco Charles dos Santos Silva (FCSS); Análise estatística, AAS e FCSS; Correções, FCSS.

Resumo

A estimativa da produtividade da soja só é realizada ao final do ciclo da cultura dificultando a gestão do escoamento e armazenamento da produção, dependem de amostragem destrutiva e conhecimento técnico. Assim, teve-se como objetivo identificar Índices de Vegetação com potencial para estimar a produtividade da soja em diferentes estádios fenológicos, utilizando imagens coletadas por sistemas-sensores com diferentes resoluções espaciais. A pesquisa foi realizada em Balsas/MA em delineamento de blocos casualizados com avaliações semanalmente da fenologia e após a colheita foi estimada a produtividade. Os produtos com os dados espectrais foram obtidos dos sensores MSI e WFI embarcados nos satélites Sentinel-2 e Amazonia-1, respectivamente. As imagens foram processadas no software Qgis para a obtenção dos valores dos pixels dos blocos e posterior cálculo dos IVs NDVI, NDWI, SAVI, VARI, IV GREEN e GLI. Os dados foram submetidos a análise de rede de correlação, como filtro para as variáveis mais próximas da produtividade, diagnóstico de multicolinearidade e análise de trilha em crista devido a identificação de multicolinearidade severa, tendo como variável principal a produtividade. A análise de rede correlação para o sistema-sensor Amazonia-1 possibilitou a filtragem das variáveis NDVI V5, NDVI R2, NDWI R5.2, VARI V5, VARI R5.1, IV GREEN V5, IV GREEN R5.1, GLI V5, GLI R5.1 e SAVI V5 e a filtragem das variáveis NDWI R5.4, VARI R2, VARI R5.2, IV GREEN R5.2, IV GREEN V8 e IV GREEN R2, para o sistema-sensor Sentinel-2. A análise de trilha para o sistema-sensor Amazonia-1 obteve coeficiente de variação de 0,88, sendo as variáveis NDVI R2 (0,42) e SAVI V5 (0,43) os maiores efeitos diretos, e para o sistema-sensor Sentinel-2 o coeficiente de variação foi de 0,86, e as variáveis com maiores efeitos diretos foram VARI R2 (0,47) e VARI R5.2 (0,5). Assim, nas condições em que foi realizado esse estudo, os índices SAVI e NDVI (infravermelho) possibilitaram satisfatoriamente a estimativa da produtividade da soja nos estádios V5 e R2, respectivamente, no sistema-sensor Amazonia-1, e o índice VARI (RGB) nos estádios R2 e R5.2, no sistema-sensor Sentinel-2. As resoluções espaciais utilizadas nesse estudo não foram fator limitante para a estimativa de produtividade da soja. Recomenda-se, o uso do índice VARI, no sistema-sensor Sentinel-2, para estimar a produtividade da soja, devido possibilitar essa estimativa em estádios reprodutivos iniciais, como o R2 e por ser um índice

RGB, possibilitando o uso de câmeras comerciais mais acessíveis em Veículos Não Tripuláveis (VANTs).

Abstract

The estimation of soybean productivity is only carried out at the end of the crop cycle, making it difficult to manage the flow and storage of production, it depends on destructive sampling and manual experience. Thus, the objective was to identify Vegetation Indices with the potential to estimate soybean productivity at different phenological stages. The research was carried out in Balsas/MA in a randomized block design with weekly assessments of phenology and after harvest, productivity was estimated. The spectral data products were obtained from the MSI and WFI sensors onboard the Sentinel-2 and Amazônia-1 satellites, respectively. The images were processed in the Qgis software to obtain the block pixel values and subsequent calculation of the IVs NDVI, NDWI, SAVI, VARI, IV GREEN and GLI. The data was subjected to neural network analysis as a filter for the variables closest to productivity, diagnosis of multicollinearity and ridge path analysis due to the identification of severe multicollinearity, with productivity as the main variable. The neural network analysis for the Amazonia-1 sensor system made it possible to filter the variables NDVI V5, NDVI R2, NDWI R5.2, VARI V5, VARI R5.1, IV GREEN V5, IV GREEN R5.1, GLI V5, GLI R5.1 and SAVI V5 and the filtering of the variables NDWI R5.4, VARI R2, VARI R5.2, IV GREEN R5.2, IV GREEN V8 and IV GREEN R2, for the Sentinel-2 sensor system. The trail analysis for the Amazonia-1 sensor system obtained a coefficient of variation of 0.88, with the variables NDVI R2 (0.42) and SAVI V5 (0.43) having the greatest direct effects, and for the sensor system Sentinel-2 coefficient of variation was 0.86, and the variables with the greatest direct effects were VARI R2 (0.47) and VARI R5.2 (0.5). Thus, under the conditions under which this study was carried out, the SAVI and NDVI (infrared) indices made it possible to satisfactorily estimate soybean productivity at stages V5 and R2, respectively, in the Amazonia-1 sensor system, and the VARI index (RGB) in stages R2 and R5.2, in the Sentinel-2 sensor system. The spatial resolutions used in this study were not a limiting factor for estimating soybean productivity. It is recommended to use the VARI index, in the Sentinel-2 sensor system, to estimate soybean productivity, as it allows this estimation in early reproductive stages, such as R2, and because it is an RGB index, enabling the use of commercial cameras. more accessible in Unmanned Vehicles (UAVs).

Introdução

A soja [*Glycine max* (L.) Merrill] é uma cultura agrícola de importância mundial, subsidiando alimentação animal e humana além da produção de biocombustíveis. Com a expectativa de que a população mundial ultrapasse os 9 bilhões até 2050 [1], a expansão da produção e da produtividade da cultura se torna um dos principais desafios da agricultura moderna.

A produtividade é uma medida do rendimento de uma cultura em uma área específica, sendo influenciada por vários fatores edafoclimáticos, que quando adequados para a cultura,

1 resultam em um bom estado fisiológico e altos níveis de produtividade [2]. Assim, a estimativas
2 de produtividade de uma determinada área possibilita entender se as condições nutricionais,
3 hídricas e sanitárias foram ou estão adequadas para possibilitar que a cultura expresse seu
4 potencial genético de produção [2].

5 Os principais métodos para quantificar essa variável são: o método manual, que consiste
6 na debulha das vagens presentes nas plantas de uma área conhecida e terminação da sua massa;
7 a partir de equações que levam em consideração a quantidade de grãos por vagem, vagens por
8 planta, planta por hectare e peso de mil grãos; e por meio de sensores nas colhedoras
9 responsáveis pela quantificação do material colhido [2].

10 Entretanto, além de onerosas e de serem dependentes de amostragem destrutiva e de
11 mão de obra com conhecimento técnico especializado, tais técnicas de estimativa de
12 produtividade, são realizadas ao final do ciclo da cultura, impossibilitando a aplicação de
13 medidas corretivas durante a condução da lavoura, além de não ser útil para a toma de decisões
14 antecipadas na organização do escoamento e do armazenamento da produção. Sendo, o
15 desenvolvimento de técnicas que permitam o monitoramento preciso e a previsão precoce do
16 rendimento da lavoura crucial para otimizar o sistema produtivo da cultura da soja.

17 Diante desta problemática, os Índices de Vegetação (IV), obtidos via sensoriamento
18 remoto orbital, podem ser ferramentas para estimar a produtividade da soja durante o seu
19 desenvolvimento. Visto que, IV disponibilizando informações sobre o potencial de produção a
20 partir da estimativa da quantidade de energia eletromagnética refletida pelo dossel da cultura,
21 após a interação da mesma com os pigmentos, água e os espaços intercelulares no interior da
22 folha [3].

23 Dentre as vantagens potenciais do uso de IV para estimar a produtividade da soja está a
24 rapidez na obtenção das imagens, que são disponibilizadas gratuitas em catálogos nos sites das
25 missões, possibilita estimar a produtividade antes do final do ciclo, permitindo a adoção de
26 medidas corretivas no manejo, bem como auxilia na gestão do escoamento e armazenamento,
27 e a pouca demanda de mão de obra para a estimação [4].

28 Nos últimos anos, diferentes estudos têm demonstrado a eficiência do uso de índices de
29 vegetação para estimar a produtividade de diferentes culturas, como arroz [5, 6], milho [7, 4, 8,
30 9] e soja [10, 8, 11, 12, 13].

31 Entretanto, em grande parte dos estudos sobre utilização de índices de vegetação na
32 estimativa de produção, os dados espectrais das culturas são obtidos no final da fase vegetativa,
33 após a abertura dos botões florais, como relatado por [14]. Sendo escassas as informações sobre

o uso de índices de vegetação dos diversos estádios de desenvolvimento da soja, na previsão da capacidade produtiva das lavouras.

Ainda mais raros são os estudos que buscam comparar a eficiência de diferentes índices de vegetação a partir de produtos com diferentes resoluções espacial para estimar a produtividade da soja. Com isso, objetivou-se identificar Índices de Vegetação com potencial para estimar a produtividade da soja em diferentes estádios fenológicos, utilizando imagens coletadas por sistemas sensores com diferentes resoluções espaciais.

Metodologia

Caracterização do local de estudo

A presente pesquisa foi desenvolvida entre abril e julho de 2022, em uma área de produção comercial de sementes de soja, com 80 ha, localizada a 30 Km do município de Balsas, MA, Brasil (Fig 1), onde o cultivar de soja TMG2383 foi conduzida sob irrigação por pivô central. O local está a 7° 31' 59" Sul, 46° 2' 6" Oeste, 243 metros de altitude e apresenta clima tropical chuvoso (Aw) e temperatura média de 27,1 °C, segundo a classificação climática de Köppen. A precipitação pluviométrica média anual é de 1175 mm, com maiores precipitações nos meses de novembro a abril, quando concentram 85% do total [15].




Fig 1. Localização da área experimental.

O solo foi classificado como Latossolo Vermelho segundo. Os dados meteorológicos de temperatura, precipitação e nebulosidade durante os meses em que a cultura estava no campo podem ser observados na Fig 02.




Fig 2. Temperatura, precipitação total, nebulosidade e insolação durante os meses de execução do experimento, em Balsas, MA no ano de 2022 [16].

Condução do experimento

O experimento foi instalado em delineamento de blocos casualizados, com quatro repetições. Cada repetição foi constituída de uma área de 5 metros de raio, para os produtos Sentinel-2, e 30 metros de raio, para os produtos Amazonia-1, cujos centros foram demarcados com um receptor Global Positioning System (GPS) de navegação.

Após a germinação da soja, foi realizado visualmente o monitoramento semanal da fenologia das plantas, de acordo com [17] (Tabela 1). Quando as plantas atingiram a maturidade plena, no estágio R8, foi realizado a avaliação da produtividade agrícola de acordo metodologia descrita por Silva et al. [2].

Tabela 1. Estádios fenológicos da soja [17]

ESTÁDIO	DESCRIÇÃO
V1	Um par de folhas unifolioladas (ou um nó);
V2	Primeiro trifólio completamente desenvolvido (ou dois nós);
V3	Dois trifólios completamente desenvolvidos (ou três nós);
Vn	Estádios vegetativos até chegar ao reprodutivo a partir da emissão do primeiro botão floral;
R1	Uma flor aberta em qualquer nó na haste principal;
R2	Uma flor aberta em um dos dois nós superiores na haste principal com folha completamente desenvolvida;
R3	Vagem de 0,5 cm a 2,0 cm em um dos quatro nós superiores na haste principal;
R4	Vagem completamente desenvolvida (> 2,0 cm) em um dos quatro nós superiores na haste principal;
R5.1, R5.2, R5.3, R5.4 e R5.5	Início do enchimento de grãos (<10% até 100% de granação) em um dos quatro nós superiores da haste principal;
R6	Grão cheio ou completo em um dos quatro nós superiores na haste principal;
R7	Início da maturação. uma vagem com coloração de madura na haste principal;
R8	Maturação Plena (colheita). mais de 95% das vagens com coloração de madura.

Como fonte de dados de reflectância utilizou-se as imagens coletadas pelo sensor *Multispectral Imager* (MSI), embarcado no satélite Sentinel-2, as quais foram obtidas no catálogo de imagens do Centro de Acesso Aberto *Copernicus* (<https://scihub.copernicus.eu/dhus/#/home>), em nível de processamento L2A. As imagens L2A possuíam correção para nuvens e sombras de nuvens, espessura óptica de aerossol, vapor de água, reflectância de superfície ortorectificada com precisão de registro multiespectral, e multitemporal de subpixel. O sensor disponibiliza produtos com resolução temporal de 5 dias,

resolução espacial que varia de 10m a 65m, resolução radiométrica de 10 bits e resolução espectral de 13 bandas, porém, no presente estudo, foram usadas apenas as bandas com resolução espacial de 10 metros (Tabela 2).

Tabela 2. Especificações técnicas do sensor MSI embarcado no satélite Sentinel-2 e do sensor WFI embarcado no satélite Amazônia-2.

Satélite	Resolução Temporal	Resolução Espectral (μm)	Resolução Radiométrica	Resolução Espacial
Sentinel-2	5 dias	Azul (0,49-0,56) Verde (0,56-0,665) Vermelho (0,665-0,842) Infravermelho Próximo (0,842-0,865)	10 bits	10 m
Amazônia-1	5 dias	Azul (0,45-0,52) Verde (0,52-0,59) Vermelho (0,63-0,69) Infravermelho Próximo (0,77-0,89)	10 bits	~65 m

Também foi utilizado, como fonte de dados de reflectância, imagens do sensor orbital WFI (*Wide Field Imager*), embarcado no satélite Amazônia-1, as quais foram obtidas no catálogo de imagens do INPE – Instituto Nacional de Pesquisas Espaciais (<http://www2.dgi.inpe.br/catalogo/explore>). O sensor disponibiliza produtos com resolução de acordo com a Tabela 02.

A escolha de ambos satélites foi realizada pela resolução temporal de 5 dias, o que permite melhor monitoramento da fenologia no decorrer do ciclo da cultura, e resolução espacial de 10 e 64 m, possibilitando a comparação da qualidade dos dados. Pois, de acordo com Bariani [18] o monitoramento da fenologia, por meio de sensores orbitais, deve possuir a maior quantidade de dados durante o ciclo, favorecendo o acompanhamento dos diferentes estádios da cultura.

A resolução temporal dos sensores proporcionou a coleta de 14 imagens para o satélite Sentinel-2 e 11 imagens para o satélite Amazônia-1, ao longo do ciclo da cultura, o que possibilitou a obtenção de informações espectrais para os estádios fenológicos de V3 a R8 (Fig 3). O critério para a seleção de imagens seguiu a disponibilidade para *download* dos respectivos catálogos de imagens e que não apresentassem cobertura total de nuvens na área de estudo.




Fig 3. Aspecto morfológico da soja nos diferentes estádios fenológicos, dos quais foram obtidas as informações espectrais pelos satélites Sentinel-2 e Amazônia-1.

Adaptado [17].

Processamento das imagens

As imagens foram processadas no *software Qgis* versão 3.26.3 [19] usando como sistema de coordenadas o *Datum* Sirgas 2000 UTM Zona 23S e submetidas as equações dos IVs da Tabela 03.

Tabela 3 - Índices de vegetação.

Tipo	Índice de vegetação	Nome	Equação	Referências
NIR	NDVI	Índice de Vegetação por Diferenciação Normalizada	$(B8-B4)/(B8+B4)$	[20]
	NDWI	Índice de Água por Diferenciação Normalizada	$(B3-B8)/(B3+B8)$	[21]
	SAVI	Índice de Vegetação Ajustado ao Solo	$(1+L)*[(B8-B4) \div (B8+B4+L)]$	[22]
RGB	VARI	Índice de Resistência Atmosférica Visível	$(B3-B4)/(B3+B4-B2)$	[23]
	GLI	Índice Folha Verde	$(2*B3-B4-B2) / (2*B3+B4+B2)$	[24]
	IV GREEN	Índices de resistência atmosférica Verde Visível	$(B3-B4)/(B3+B4)$	[23]

B4: refletância no vermelho, B8: refletância no infravermelho próximo, B3: refletância no verde; B2: refletância no azul; L = fator de ajuste podendo variar de 0 a 1.

1 **Tabela 4. Comportamento dos índices de vegetação (IVs) ao longo do ciclo da soja, para**
2 **os produtos Sentinel-2**

IV	NDVI	NDWI	SAVI	IVGREEN	GLI	VARI
V3						
V5						
V8						
R1						
R2						
R3						
R4						
R5.1						
R5.2						
R5.4						
R5.5						
R6						
R7						
R8						

3































4

5

6

7

Tabela 5. Comportamento dos índices de vegetação (IVs) ao longo do ciclo da soja, para os produtos Amazonia-1

IV	NDVI	NDWI	SAVI	IVGREEN	GLI	VARI
V3						
V5						
V8						
R1						
R2						
R4						
R5.1						
R5.2						
R5.4						
R5.5						
R8						

Estatística

Com auxílio programa Genes [25] os dados obtidos foram submetidos ao teste F da análise de variância, onde se buscou verificar a existência de diferença significativa entre as repetições e entre os estádios fenológicos, ao longo do ciclo da cultura, para os diferentes índices de vegetação (IV).

Para cada sistema sensor, as variáveis (IVs e produtividade) que apresentaram diferenças significativas entre os estádios morfológicos foram submetidas a análise de correlação de Pearson. A matriz de correlações atribuída ao sistema-sensor Sentinel-2, foi constituída por 85 variáveis [84 informações de índices de vegetação (6 índices em 14 estádios fenológicos) mais a variável produtividade de grãos]. Para o sistema-sensor Amazonia-1 a matriz de correlações foi constituída por 67 variáveis [66 informações de índices de vegetação (6 índices em 11 estádios fenológicos) mais a variável produtividade de grãos].

Para facilitar a interpretação, a matriz de correlações obtidas foi representada utilizando a técnicas de redes de correlações, nas quais, as conexões entre variáveis são determinadas “adjacência matriz”, de acordo com a Equação 1:

$$h(hrij) = \frac{1}{2} \{sgn(|rij| - p) + 1\} \quad (1)$$

Em que: p é o parâmetro “*hard threshold*”, que foi definido como 0,7, de modo que possam ser vistas apenas as conexões entre variáveis que possuam correlações iguais ou superiores a 0,7.

As redes de correlações obtidas foram utilizadas como filtro para a seleção das variáveis a serem empregadas na análise de trilha, de modo que apenas as variáveis (índices de vegetação em diferentes estádios fenológicos) que, na rede de correlações, apresentarem ligação com a produtividade de grãos, ou que apresente ligação com uma das variáveis com ligação direta com a produtividade de grãos, foram selecionadas para realização da análise de trilha.

Para ambos os sistema-sensor estudados, após a identificação das variáveis a serem submetidas à análise de trilha, e antes da realização dessa última, a matriz de correlações dessas variáveis selecionadas passaram pelo diagnóstico de multicolinearidade conforme Cruz e Regazzi [26]. O grau de multicolinearidade da matriz de correlações, entre as variáveis independentes do modelo de trilha, foi considerado severo, pois a razão entre o maior e o menor autovalor da matriz de correlações foi superior a 1000. Assim, empregou-se a metodologia, denominada análise de trilha em crista, em que a constante (k) de 5,25 foi introduzida à diagonal da matriz $X'X$ [27].

Resumo da metodologia

Um resumo da metodologia utilizada na presente pesquisa está ilustrado na Fig 4.




Fig 4. Resumo da metodologia da pesquisa.

Resultados e Discussão

A análise de variância dos dados dos Índices de Vegetação (IVs) possibilitou observar que não houve diferença significativa entre as repetições, mas houve diferença entre os estádios fenológicos, demonstrando que todos os índices apresentam variações à medida que as plantas se desenvolviam (Tabela 6). Vários autores relatam diferença entre os estádios fenológicos da soja ao utilizarem IV para seu monitoramento, sendo esta diferença caracterizada por baixos valores no início do ciclo, cresce gradualmente até um máximo de biomassa e decresce com o término do ciclo da cultura [28, 29, 30, 31, 32, 33, 34, 4].

1 **Tabela 6. Resumo da análise de variância dos dados dos sistemas-sensores estudados.**

IV	F calculado			
	----- SENTINEL 2 -----		----- AMAZONIA 1 -----	
	Repetição	Estádios	Repetição	Estádios
NDVI	1,170 ns	78,740 **	1,180 ns	6,220 **
NDWI	0,690 ns	4,893 **	0,207 ns	106,470 **
SAVI	1,070 ns	79,980 **	1,150 ns	34,750 **
VARI	2,550 *	189,270 **	1,610 ns	82,250 **
GLI	1,380 ns	155,280 **	0,920 ns	28,850 **
IV GREEN	0,5380 ns	97,340 **	2,580 ns	13,170 **

2 ** e * indica significância a 1 e 5% de probabilidade, respectivamente, pelo teste F.

3
4 Os índices VARI e GLI, para o sistema-sensor Sentinel-2, e os índices NDWI e VARI,
5 para o sistema-sensor Amazonia-1, apresentaram maior variabilidade de dados, sendo possível
6 relatar que esses índices apresentaram maior sensibilidade às mudanças nos estádios
7 fenológicos da cultura (Tabela 6). Tais observações são relevantes visto que, índices diferentes
8 com sensibilidades distintas à variação no crescimento e desenvolvimento da planta também
9 podem apresentar disparidade quanto às eficiências na estimativa da produtividade da soja.

10 Tal como para Bai et al. [35] que observou eficiência superior no índice VARI, em
11 relação a outros índices, como o SAVI, para estimar peso de grão por plantas e grãos por planta.
12 Assim como Joshi et al. [36] que observou a correlação de 12 índices de vegetação com a
13 produtividade, observando as maiores correlações nos estádios reprodutivos R2 e R3 para todos
14 os índices, mas com correlações mais significativas para índices específicos, demonstrando
15 sensibilidades distintas à variação no crescimento e desenvolvimento da planta.

16 Após a identificação da diferença entre os estádios fenológicos nos IV analisados
17 (Tabela 6), foi utilizado uma análise de correção para identificar os índices que possuíam maior
18 correlação com a produtividade de grãos. Devido ao grande número de variáveis, foi utilizada
19 a rede de correlação para expressar graficamente os resultados, em que a proximidade entre as
20 variáveis é proporcional ao valor absoluto da correlação entre as mesmas [37].

21 A análise gráfica de rede de correlações, para o sistema-sensor Sentinel-2, evidenciou
22 que os índices NDWI R5.4, VARI R2, VARI R5.2, IV GREEN R5.2, IV GREEN V8 e IV
23 GREEN R2 são os mais associados com a variável produtividade de grãos (Fig 3). Em contraste,
24 para o sistema de sensoriamento Amazonia-1, os índices NDVI V5, NDVI R2, NDWI R5.2,
25 VARI V5, VARI R5.1, IV GREEN V5, IV GREEN R5.1, GLI V5, GLI R5.1 e SAVI V5
26 demonstraram as correlações mais fortes com a produtividade de grãos de soja (Fig 3).




Fig 5. Redes de correlações envolvendo a produtividade de grãos de soja e índices de vegetação (IV) obtidos com sistemas-sensores do Sentinel-2 e Amazonia-1.

A presença de linhas ligando duas variáveis indica que a correlação entre essas variáveis é superior a 0,7; linha vermelha indica a correlação superior a 0,7 entre o IV e a produtividade, linha verde indicam correlação superior 0,7 entre IVs, sendo que um dos índices envolvidos apresentou correlação superior a 0,7 com a produtividade de grãos.

A análise de rede de correlação mostrou-se eficiente na identificação de índices com alta correlação com a produtividade da soja, mas a quantificação da relação de causa e efeito entre esses grupos de variáveis é realizado pela análise trilha. Essa técnica tem a capacidade de particionar o coeficiente de correlação para quantificar as relações diretas e indiretas de todas as variáveis envolvidas na resposta, uma a uma [26]. Tal fato proporciona maior confiabilidade na determinação do índice e do momento que o mesmo deve ser obtido para potencializar a qualidade da previsão da produtividade.

Da Silva et al. [13] constataram que as redes de correlações são eficazes na seleção de índices de vegetação para serem utilizados na análise de trilha, com o objetivo de prever a produtividade da soja.

A análise de trilha sob multicolinearidade para ambos os satélites avaliados nesse estudado apresentaram altos coeficientes de determinação, garantindo confiabilidade nos dados. As variáveis SAVI V5 e NDVI R2 apresentaram os maiores efeitos diretos sobre produtividade (PROD) para o sistema-sensor Amazonia-1 (Tabela 7), assim como as variáveis VARI R2 e VARI R5.2 para o sistema-sensor Sentinel-2 (Tabela 8).

Tabela 7. Análise de trilha sob multicolinearidade para o sistema-sensor Amazonia-1.

	EFEITO	NDVI V5	NDVI R2	NDWI R5.2	VARI V5	VARI R5.1	IV GREEN V5	IV GREEN R5.1	GLI V5	GLI R5.1	SAVI V5
Direto	PROD	0,2739	0,4227	0,1775	-0,0962	0,0665	0,2588	0,2801	-0,2332	-0,6341	0,4375
	NDVI V5	-	0,2633	0,1768	0,2159	0,1917	0,2220	0,1800	0,2130	0,2492	0,1945
	NDVI R2	0,4063	-	0,2499	0,2962	0,2184	0,3097	0,1993	0,3510	0,3916	0,2746
	NDWI R5.2	0,1146	0,1050	-	0,0421	0,0733	0,0459	0,0626	0,0468	0,0937	0,1105
Indireto	VARI V5	-0,0758	-0,0674	-0,0228	-	0,0631	-0,0945	-0,0628	-0,0817	-0,0668	-0,070
	VARI R5.1	0,0465	0,0343	0,0274	0,0436	-	0,0448	0,0662	0,0237	0,0420	0,0311
	IV GREEN V5	0,2098	0,1896	0,0669	0,2546	0,1745	-	0,1734	0,2243	0,1894	0,1712
	IV GREEN R5.1	0,1841	0,1321	0,0988	0,1830	0,2788	0,1877	-	0,0940	0,1639	0,1284
	GLI V5	-0,1813	-0,1937	-0,0615	-0,1982	-0,0834	-0,2021	-0,0782	-	-0,1920	-0,1462
	GLI R5.1	-0,5769	-0,5875	-0,3348	-0,4403	-0,4006	-0,4641	-0,3710	-0,5219	-	-0,3428
	SAVI V5	0,3106	0,2842	0,2723	0,3184	0,2048	0,2894	0,2005	0,2743	0,2365	-
Coeficiente de Determinação			0,88								
Efeito Residual			0,33								

São considerados relevantes efeitos diretos ou indiretos com magnitudes superiores ao efeito residual.

Tabela 8. Análise de trilha sob multicolinearidade para o satélite Sentinel-2.

	EFEITOS	NDWI R5.4	VARI R2	VARI R5.2	IV GREEN R5.2	IV GREEN V8	IV GREEN R2
Direto	PROD	0,0353	0,4715	0,5008	-0,0847	0,0453	0,1729
	NDWI R5.4	-	0,0084	0,0068	0,0138	-0,0004	-0,0074
	VARI R2	0,1121	-	0,1889	0,3662	0,2607	0,1742
Indireto	VARI R5.2	0,0969	0,2007	-	0,3460	0,3624	0,4199
	IV GREEN R5.2	-0,0332	-0,0658	-0,0585	-	-0,0515	-0,0591
	IV GREEN V8	-0,0006	0,0250	0,0328	0,0275	-	0,0303
	IV GREEN R2	-0,0362	0,0638	0,1449	0,1207	0,1158	-
Coeficiente de Determinação		0,86					
Efeito Residual		0,36					

São considerados relevantes efeitos diretos ou indiretos com magnitudes superiores ao efeito residual.

1 Para os produtos do sistema-sensor Amazonia-1, o índice NDVI obtido no estágio R2
2 teve efeito direto de 0,42 sobre a produtividade (Tabela 7), sendo este estágio caracterizado por
3 uma flor aberta em um dos dois nós superiores na haste principal com folha completamente
4 desenvolvida. Tal resultado vai ao encontro do que foi relatado por Trindade et al. (2019), onde,
5 na cultura da soja, o índice NDVI no estágio R2 alcançou $R^2 = 0,44$ com a produtividade.

6 Para o mesmo sistema-sensor, o índice SAVI obtido no estágio V5 teve efeito direto de
7 0,43 sobre a produtividade (Tabela 7), sendo este estágio caracterizado por quatro trifólios
8 completamente desenvolvidos. Tal resultado corrobora o estudo de Da Silva et al. [13], onde
9 observaram que o SAVI no estágio V4 da soja teve efeito direto de 0,26 pela análise de trilha
10 com coeficiente de determinação de 0,93. Assim, tal índice torna-se vantajoso para a tomada
11 de decisões antecipadas na organização do escoamento e do armazenamento da produção.

12 Estes resultados podem ser justificados pela banda do infravermelho próximo, utilizada
13 no cálculo do NDVI e SAVI, que estima o acúmulo de biomassa, devido estar relacionado as
14 estruturas foliares, e diminuição da interferência do solo no índice SAVI, refletindo seus
15 potenciais preditivo de produtividade [38, 13].

16 Já para os produtos do sistema-sensor Sentinel-2, o índice VARI nos estádios R2 e R5.2,
17 apresentaram efeitos diretos mais relevantes sobre a capacidade produtiva da soja (Tabela 8).
18 Estes estádios caracterizados por uma flor aberta em um dos dois nós superiores na haste
19 principal com folha completamente desenvolvida e início do enchimento de grãos (<50% de
20 granação) em um dos quatro nós superiores da haste principal, respectivamente

21 A eficiência do índice VARI nos estádios reprodutivos (Tabela 8) para a estimativa de
22 variáveis de produtividade também é relatada por Bai et al. [35]. Esse índice é minimamente
23 sensível aos efeitos atmosféricos, devido a subtração da banda do azul na sua equação,
24 permitindo a estimativa da vegetação com um erro <10%, pois se relaciona apenas com os
25 pigmentos da folha (clorofila, carotenoides, antocianinas e xantofilas), possibilitando a
26 estimativa da produtividade da soja em estádios reprodutivos que representam o seu máximo
27 desenvolvimento e crescimento [38, 23]. Devido a relação do VARI com pigmentos foliares,
28 este índice torna-se eficiente nos estádios reprodutivos da cultura devido a relação com a
29 produtividade, onde Yokoyama et al. [39] observou correlação de 0,33 e 0,54 entre o teor de
30 clorofila medida por clorofilômetro e produtividade nos estádios R2 e R5.3, respectivamente.

31 Índices RGB como o VARI tem recebido bastante atenção devido a possibilidade de sua
32 aplicação partir dos dados coletado por câmeras simples e de baixo custo que podem ser
33 embarcadas em Veículos Aéreos Não Tripulados (VANTs) [40].

Os índices NDVI e VARI foram eficientes na previsão de produtividade no início dos estádios reprodutivos devido estarem relacionados as estruturas e pigmentos foliares, respectivamente. Tal resultado pode ser explicado pela relação fonte e dreno, pois nesses estádios iniciais há uma maior demanda de produção de fotoassimilados para suprir a os drenos, como flores e vagens, também sendo esses estádios os de máximo crescimento e desenvolvimento da cultura [38].

Os resultados demonstram que os sistemas-sensores estudados apresentaram eficácia semelhante quanto à precisão na estimativa de produtividade da soja, com valores de coeficientes de determinação sendo próximos (0,88 e 0,86) (Tabelas 7 e 8). Demonstrando que a variação da resolução espacial de 64 metros do sensor *Wide Field Imager* (WFI) embarcado nesse satélite Amazonia-1 e a resolução espacial de 10 metros do sensor *Multispectral Imager* (MSI) embarcado no satélite Sentinel-2, não é fator limitante na estimativa de produtividade da soja, ao menos em grandes áreas de cultivos, como foi o caso desse estudo. Resultados semelhantes foram encontrados por Bolton e Friedl [4] que utilizaram sensores com resoluções espacial de 56 e 500 metros para estimar a produtividade da soja e encontraram correlações de 0,73 e 0,68 para os índices EVI e NDWI, respectivamente.

Os sistemas sensores apresentaram, como melhores preditores de produtividades, índices diferentes, sendo os índices com a banda do infravermelho melhores nos produtos Amazonia-1 (Tabela 7) e os índices RGB nos produtos Sentinel-2 (Tabela 8). Tal resultado foi observado por Johnson (2014), onde utilizando NDVI com resolução espacial de 250 m, possibilitou a previsão de produtividade da soja com correlação de 0,49. O autor afirma que resoluções maiores podem mascarar valores de interferências atmosféricas, umidade e de solo. Amankulova et al. [41], também observou que índices com infravermelho tiveram melhor relação na predição de produtividade em produtos com maior resolução (30m) do que produtos com menor resolução (10m).

A menor resolução espacial do sistema-sensor Sentinel-2 proporcionou a melhor predição com o índice VARI devido uma menor interferência atmosférica, ocasionada pela subtração da banda azul na sua equação e devido a detecção da variabilidade espacial no campo, pois os pixels da imagem são menores [38, 23].

Todavia, são necessários estudos para averiguar a eficiência desses sistemas-sensores na estimativa de produtividade da soja com a variação da área de cultivo imaginada.

Conclusões

Nas condições em que foi realizado esse estudo, os índices SAVI e NDVI (infravermelho) possibilitaram a estimativa da produtividade da soja nos estádios V5 e R2, respectivamente, no sistema-sensor Amazonia-1, e o índice VARI (RGB) nos estádios R2 e R5.2, no sistema-sensor Sentinel-2.

As resoluções espaciais utilizadas nesse estudo não foram fator limitante para a estimativa de produtividade da soja.

Recomenda-se, o uso do índice VARI, no sistema-sensor Sentinel-2, para estimar a produtividade da soja, devido possibilitar essa estimativa em estádios reprodutivos iniciais, como o R2 e por ser um índice RGB, possibilitando o uso de câmeras comerciais mais acessíveis em Veículos Aéreos Não Tripuláveis (VANTs). Assim, como oportunidade de novos estudos, será necessário realizar a validação do método em diferentes cultivares.

Referências

1. ONU, “World Population Ageing 1950-2050”, Department of Economic and Social Affairs, Population Division, United Nations, New York, 2021.
2. Silva F, Borem A, Sedyama T, Câmara G. Soja: do plantio à colheita. 2ª edição. São Paulo: Oficina de Textos;2022.
3. Oliveira M, Queiroz T, Teixeira A, Moreira L, Leão R, Espectrometria de reflectância aplicada à análise das deficiências de nitrogênio e potássio em algodoeiro. Revista Ciência Agronômica. 2020;51(4). Português.
4. Bolton D, Friedl M. Forecasting Crop Yield Using Remotely Sensed Vegetation Indexes and Crop Phenology Metrics. Agricultural and Forest Meteorology. 2013;173:74-84.
5. Kanke Y, Tubana B, Dalen M, Harrel D. Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. Precision Agriculture. 2016;17(5):507-530.
6. Rehman TH, Reis AF, Akbar N, Linquist BA. Use of normalized difference vegetation index to assess N status and predict grain yield in rice. Agronomy Journal. 2019;111(6):2889-2898.

- 1 7. Baez-Gonzalez AD, Chen PY, Lopes M. Using Satellite and Field Data with Crop Growth
2 Modeling to Monitor and Estimate Corn Yield in Mexico. *Ciência agrícola*. 2002;6:1943-
3 1949.
- 4 8. Dong J, Xiao X, Wagle P, Zhang G, Zhou J, Jin C, et al. Comparison of four EVI-based
5 models for estimating gross primary production of maize and soybean croplands and
6 tallgrass prairie under severe drought. *Remote Sensing of Environment*. 2015;162:154-
7 168.
- 8 9. Garcia-Martinez H, Flores-Magdaleno H, Ascencio-Hernández R, Gardezi AK, Tijerina-
9 Chávez L, Mancilla-Villa OR, et al. Corn grain yield estimation from vegetation indices,
10 canopy cover, plant density, and a neural network using multispectral and RGB images
11 acquired with unmanned aerial vehicles. *Agriculture*. 2020;10(7):277.
- 12 10. Holzman M, Rivas R, Piccolo M. Estimating soil moisture and the relationship with crop
13 yield using surface temperature and vegetation index. *International Journal of Applied*
14 *Earth Observation and Geoinformation*. 2014;28:181-192.
- 15 11. Christenson, BS, Xiao X, Wagle P, Zhang G, Zhou J, Jin C, et al. Predicting soybean
16 relative maturity and seed yield using canopy reflectance. *Crop Science*. 2016;56(2):625-
17 643.
- 18 12. Schwalbert RA, Amado T, et al. Satellite-based soybean yield forecast: Integrating
19 machine learning and weather data for improving crop yield prediction in southern
20 Brazil. *Meteorologia Agrícola e Florestal*. 2020;107886.
- 21 13. Da Silva EE, Baio FH, Teodoro L, Silva C, Borges A, Teodoro P. UAV-multispectral and
22 vegetation indices in soybean grain yield prediction based on in situ observation. *Remote*
23 *Sensing Applications: Society and Environment*. 2020;18:100318.
- 24 14. Marti J, Bort J, Slafer GA, Araus JL. Can wheat yield be assessed by early measurements
25 of normalized difference vegetation index?. *Annals of Applied biology*. 2007;150(2):253-
26 257.
- 27 15. Passos ML, Zambrzycki, GC, Pereira RS. Balanço hídrico climatológico e classificação
28 climática para o município de Balsas - MA. *Revista Scientia Agraria*. 2017;18:83-89.
29 Português.
- 30 16. Inmet, Instituto Nacional de Meteorologia do Brasil. Disponível em:
31 <https://portal.inmet.gov.br/>. Acessado em: 17 out. 2022.

- 1 17. Oliveira Júnior A, Castro C, Pereira L, Domingos C. Estádios fenológicos e marcha de
2 absorção de nutrientes da soja. Embrapa Milho e Sorgo-Boletim de Pesquisa e
3 Desenvolvimento (INFOTECA-E), 2016. Português.
- 4 18. Bariani C, Kerstini DS, Victoria NM, Carlesso R, Petry MT, Peripolli M. Monitoramento
5 da fenologia da soja irrigada usando perfis de série temporal de NDVI. III encontro
6 internacional INOVAGRI. 2015:1610-1618. Português.
- 7 19. QGIS. Geographi Information System QGIS. Disponível em: <http://www.qgis.org>. Acesso
8 em: 09 maio 2022.
- 9 20. Rouse JW, Haas RH, Schell JA, Deering DW, Harlan JC. Monitoring the vernal
10 advancement and retrogradation of natural vegetation. Greenbelt: National Aeronautics
11 and Space Administration. 1974:371.
- 12 21. Mc Feeters SK. The use of the Normalized Difference Water Index (NDWI) in the
13 delineation of open water features. International Journal of Remote Sensing.
14 1996;17:1425-1432.
- 15 22. Huete AR. A soil ajusted vegetation index (SAVI). Remote Sensing Environ. 1988:25.
- 16 23. Gitelson A, Kaufman Y, Stark R, Rundquist D. Novel algorithms for remote estimation of
17 vegetation fraction. Remote Sensing of Environment. 2002;80:76–87.
- 18 24. Louhaichi M, Borman M, Jhonson D. Spatially Located Platform and Aerial Photography
19 for Documentation of Grazing Impacts on Wheat. Geocarto International, 2001;16:65-70.
- 20 25. Cruz CD. Genes Software - extended and integrated with the R, Matlab and Selegen. Acta
21 Scientiarum, 2016;38:547-552.
- 22 26. Cruz CD, Regazzi AJ. Modelos biométricos aplicados ao melhoramento genético. UFV,
23 Viçosa, Brasil. 1997.
- 24 27. Carvalho CG, Oliveira VR, Cruz CD, Casali VW. Análise de trilha sob multicolinearidade
25 em pimentão. Pesquisa Agropecuária Brasileira. 1999;34(4):603-613. Português.
- 26 28. Rodrigues C, Fontana D, Moraes O, Roberti D. NDVI e fluxo de CO₂ em lavoura de soja
27 no Rio Grande do Sul. Revista Brasileira de Meteorologia. 2013;28:95-104. Português.
- 28 29. Estevam V, Reges N, Dos Santos M. Uso do índice ndvi para determinação fenológica da
29 cultura da soja. Revista uniaraguaia. 2023;18:106-115. Português.
- 30 30. Breaban LG, Stoleriu AP. Monitoring the crops phenology using time series sentinel 2
31 images. Acta Geobalcanica (Skopje.Online). 2020;6:95-102.

31. Hatfield J, Pruger J. Value of Using Different Vegetative Indexes to Quantify Agricultural Crop Characteristics at Different Growth Stages under Varying Management Practices. *Remote Sens.* 2010;2:562-579.
32. Sakamoto T, Gitelson A, Nguy-Rbertson A, Arquebauer T, Wardlow B, Suyker A, et al. An Alternative Method Using Digital Cameras for Continuous Monitoring of Crop Status. *Agricultural and Forest Meteorology.* 2012;154:113-26.
33. Ge H, MA F, Li Z, Tan Z, Du C. Improved Accuracy of Phenological Detection in Rice Breeding by Using Ensemble Models of Machine Learning Based on UAV-RGB Imagery. *Remote Sensing,* 2021;11:2439.
34. Guo Y, Xiao Y, Hao F, Zhang X, Sol H, Beurs K, et al. Identifying crop phenology using maize height constructed from multi-sources images. *International Journal of Applied Earth Observation and Geoinformation.* 2022;115:103-121.
35. Bai D, Li D, Zhao C, Shao M, Guo B, Liu Y, Wang Q, et al. Estimation of soybean yield parameters under lodging conditions using rgb information from unmanned aerial vehicles. *Frontiers in Plant Science.* 2022;13:1012293.
36. Joshi DR, Clay SA, Shama P, Kharel T, Rizzo DM, Thapa R, et al. Artificial Intelligence and Satellite Based Remote Sensing can be used to Predict Soybean (*Glycine max*) Yield. *Agronomy Journal.* 2023.
37. Bhering LL. Rbio: A tool for biometric and statistical analysis using the R platform. *Crop Breeding and applied biotechnology.* 2017;17:187-190.
38. Ponzoni FJ, Shimabukuro, Y. E.; Kuplich, T. M. Sensoriamento remoto da vegetação. 2. ed.; Oficina de Textos: São Paulo, Brasil, 2012;160. Português.
39. Yokoyama AH, Junior A, Zucareli C, Ribeiro R. Índice de área foliar e SPAD durante o ciclo da soja em função da densidade de plantas e sua relação com a produtividade de grãos. *Revista de Ciências Agroveterinárias.* 2018;17(4):531-538. português.
40. Viana S, Girao R, Bendahan A, Freitas V. Análise visual de índices de vegetação utilizando imagens RGB para classificação de áreas de pastagens com presença de plantas invasoras. *Semana Nacional de Ciência e Tecnologia.* 2020;15:70-74. Português.
41. Amankulova K, Farmonov N, Akramova P, Tursunov I, Mucsi L. Comparison of PlanetScope, Sentinel-2, and landsat 8 data in soybean yield estimation within-field variability with random forest regression. *Heliyon.* 2023;9(6).