

## DETECÇÃO DAS FASES FENOLÓGICAS DO ALGODOEIRO UTILIZANDO PRODUTOS SENTINEL-2 E ALGORITMO RANDOM FOREST

Sulimar Munira Caparoci Nogueira<sup>1</sup>, Adâmara Santos Gonçalves Felício<sup>2</sup>, Alber Hamersson Sánchez Ipia<sup>3</sup>

<sup>1</sup> IDGeo - Inteligência Agrícola, sulini.nogueira@gmail.com; <sup>2</sup> Fundação de Estudos Agrários Luiz de Queiroz - FEALQ, adamarafelicio@gmail.com; <sup>3</sup> Instituto Nacional de Pesquisas Espaciais – INPE, albhasan@gmail.com

### RESUMO

O monitoramento das fases fenológicas em alta resolução espaço-temporal pode auxiliar na gestão precisa e eficiente da agricultura, garantindo melhor gestão de recursos. O potencial de produtos derivados de séries temporais Sentinel-2 para identificar as fases fenológicas do algodoeiro irrigado foi avaliado usando o algoritmo Random Forest (RF). Os resultados demonstraram que índices de vegetação derivados de imagens Sentinel-2 são capazes de capturar os estágios fenológicos de emergência (1), vegetação (2), reprodução (3) e senescência (4). A acurácia da classificação das fases 1 – 2, 2 – 3 e 3 – 4 foram de 96,4%, 98,3% e 93,1%, respectivamente. Esses resultados demonstram que as métricas fenológicas têm alto potencial para classificação das fases fenológicas da cultura algodoeira e, portanto, podem ser utilizadas por especialistas no gerenciamento e monitoramento agrícola.

**Palavras-chave** — agricultura; sensoriamento remoto; séries temporais; média resolução; monitoramento agrícola.

### ABSTRACT

Monitoring phenological phases in high spatio-temporal resolution is part of a precise and efficient agriculture as well as better resource management. In this work, we used time series from Sentinel2 (S2) imagery to identify the phenological phases of cotton trees by means of the Random Forest algorithm. We found that S2 vegetation indices capture the phenological phases of emergence (1), vegetation (2), reproduction (3) and senescence (4) with an accuracy of 96.3% (phases 1–2), 98.3% (phases 2–3), and 93.1% (phases 3–4). These results show the potential of phenological metrics for classifying the cycle of cotton trees and are an additional tool for managing and monitoring crops.

**Key words** — agriculture, remote sensing, time series, medium resolution, agricultural monitoring.

### 1. INTRODUÇÃO

O algodão, uma das culturas fibrosas mais importantes do mundo, movimenta anualmente US\$ 12 bilhões e sua cadeia produtiva emprega cerca de 350 milhões de pessoas [1]. O

Brasil, quarto maior produtor mundial de algodão, possui área de cultivo de 1,5 milhão de hectares distribuídas entre os estados do Mato Grosso, Bahia, Minas Gerais, Goiás, Mato Grosso do Sul, Maranhão, Piauí, São Paulo, Tocantins e Paraná [1].

Dada a extensão das áreas cultivadas, técnicas de sensoriamento remoto podem ser empregadas na aquisição de informações que auxiliem os agricultores na tomada de decisão em tempo hábil e a baixo custo, garantindo gestão precisa e eficiente da agricultura [2]. O monitoramento oportuno da fenologia da cultura em alta resolução espaço-temporal pode auxiliar na programação de operações de fertilizantes, reguladores de crescimento e colheita, irrigação e drenagem [3], além do manejo de pragas [4], garantindo dessa forma melhor gestão de recursos [5].

O cultivo das espécies vegetais passa pelas etapas de preparo do solo, plantio, crescimento vegetativo, desenvolvimento reprodutivo (maturação), senescência e colheita. Essa sucessão de diferentes escalas de cobertura vegetativa sobre a superfície influencia diretamente o comportamento espectral registrado pelas bandas dos sistemas sensor/satélite orbitais [6]. As bandas espectrais podem ser combinadas matematicamente na forma de índices de vegetação (IV) para avaliar e caracterizar a cobertura vegetal de acordo com a reflectância dos alvos e podem ser aplicados para construir perfis sazonal e temporal das atividades da vegetação. Em culturas agrícolas é possível avaliar as características sazonais e fenológicas, duração do período de crescimento e senescência das culturas ([7], [8], [9]).

Begue et al. [10] acompanhou o início do desenvolvimento fenológico de áreas de pastagens e terras cultivadas utilizando o produto fenologia global MCD12Q2/MODIS. Ju et al. [11] usou a correlação entre a duração das fases fenológicas, taxa de crescimento da cultura de milho e máximo valor de NDVI para construir modelos de previsão de rendimento em larga escala.

Com base no que foi exposto acima, a pesquisa baseia-se na hipótese de que os dados de sensoriamento remoto podem ser utilizados no acompanhamento e detecção das fases fenológicas de cultivos agrícolas. Desse modo, o trabalho propõe-se a estabelecer metodologia que auxilie profissionais do setor algodoeiro a estimar as fases fenológicas da cultura utilizando dados de sensoriamento remoto. O objetivo do presente trabalho é desenvolver uma metodologia de monitoramento em tempo (quase) real do estágio fenológico do algodoeiro utilizando produtos Sentinel-2.

## 2. MATERIAL E MÉTODOS

### 2.1 Área de estudo

O estudo foi realizado em 60 talhões de cultivo de algodão, localizado entre as latitudes sul 11°43' e 19°52' e as longitudes 45°5' e 55°18' (Figura 1), no período compreendido entre os anos safra 2020 e 2021. A localização dos talhões e as fases fenológicas foram cedidas pela empresa de monitoramento agrícola IDGeo – Inteligência Agrícola.

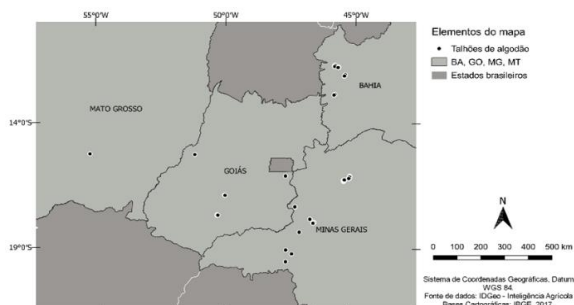


Figura 1. Localização das áreas de cultivo do algodão nos Estados de Mato Grosso, Minas Gerais, Goiás e Bahia.

### 2.2 Monitoramento das fases fenológicas

As quatro fases fenológicas estudadas podem ser definidas conforme descrição a seguir ([12], [13], [14]):

- (1) **Semeadura à Emergência:** sementes são colocadas no solo, nessa etapa há apenas o comportamento do solo exposto sendo capturado pelo sensor.
- (2) **Fase vegetativa:** a fase se estende da emergência das plantas até o aparecimento do primeiro botão floral.
- (3) **Fase reprodutiva:** período de máximo desenvolvimento vegetativo, ou seja, o cultivo apresenta máximo desenvolvimento foliar e recobrimento total do solo.
- (4) **Maturação:** capulhos abrindo, ou seja, quando as fibras brancas são visíveis em pelo menos uma cápsula. Nesse estágio ocorre a senescência da planta, com diminuição da capacidade fotossintética.

Na Figura 2 é ilustrado o desenvolvimento fenológico da cultura do algodão.




Figura 2. Desenvolvimento fenológico do cultivo  
Fonte: Adaptado de AgroPós (2022)

### 2.3 Dados Sentinel-2

Nesse estudo foram utilizados dados do satélite Sentinel-2 L2A que fornece um conjunto de 10 bandas espectrais que vão do visível e infravermelho próximo ao infravermelho de ondas curtas que podem ser utilizadas nos estudos do comportamento espectral da vegetação e uma banda SCL de

classificação de cena, que no estudo foi utilizada no mascaramento de nuvens/sombra.

Dada a diferença de resolução espacial entre as bandas, as imagens de 20m (bandas 5, 6, 7, 8A, 11 e 12) foram reamostradas para 10 m utilizando-se o algoritmo de interpolação vizinho mais próximo. A partir dos talhões de algodão foi feita a seleção dos pixels completamente ocupados pela cultura algodoeira (pixels puros) para evitar a mistura espectral por alvos distintos dentro do conjunto de dados. Destes pixels foram extraídos os valores das bandas individuais que, posteriormente, foram utilizadas na geração de IVs (Tabela 1).

Equação	Referência
$CI_{red-edge} = \frac{\rho_{B07} - 1}{\rho_{B05}}$	[15]
$NDVI = \frac{\rho_{B07} - \rho_{B03}}{\rho_{B07} + \rho_{B03}}$	[16]
$IRECI = \frac{\rho_{B07} - \rho_{B04}}{\rho_{B05}/\rho_{B06}}$	[17]
$NDI54 = \frac{\rho_{B05} - \rho_{B04}}{\rho_{B05} + \rho_{B04}}$	[18]
$NDSVI = \frac{\rho_{B11} - \rho_{B04}}{\rho_{B11} + \rho_{B04}}$	[19]
$NDVI = \frac{\rho_{B08} - \rho_{B04}}{\rho_{B08} + \rho_{B04}}$	[20]
$NDWI = \frac{\rho_{B08} - \rho_{B11}}{\rho_{B08} + \rho_{B11}}$	[21]
$NDWI12 = \frac{\rho_{B08} - \rho_{B12}}{\rho_{B08} + \rho_{B12}}$	[21]
$SLAVI = \frac{\rho_{B08}}{\rho_{B04} + \rho_{B12}}$	[22]
$SR_{re} = \frac{\rho_{B08}}{\rho_{B05}}$	[23]

Tabela 1. Sumário de índices de vegetação

Os Ivs foram transformados para a mesma ordem de grandeza utilizando a técnica de padronização na qual as variáveis transformadas apresentam média igual a 0 e desvio padrão igual a 1 [24].

### 2.4 Modelagem dos dados espectrais

O algoritmo Random Forest foi utilizado para gerar modelos de classificação supervisionado das fases fenológicas. Foi feita a validação cruzada pelo método do K-Fold no conjunto de amostras. Na validação cruzada (k-fold, k = 10) o conjunto de observações foi dividido aleatoriamente em 10 grupos de tamanhos iguais. Os dados foram analisados através da matriz de confusão, a partir da qual foram analisadas a precisão, o recall e a acurácia da classificação.

## 3. RESULTADOS E DISCUSSÃO

### 3.1 Seleção de features e separabilidade das classes

O algoritmo foi utilizado na seleção das features sensíveis à identificação das fases fenológicas. Os resultados das análises

1-2, 2-3 e 3-4 são mostrados nas Figuras 3 (a), (b) e (c), respectivamente. Os índices IRECI (*Inverted red-edge chlorophyll index*) e CIred-edge (*red-edge chlorophyll index*) tiveram maior impacto na distinção entre as fases 1-2 e 3-4. O IRECI usa a reflectância da região da borda vermelha, região do espectro associada a forte absorção da clorofila e espalhamento causado pelas folhas. O índice CI<sub>rededge</sub> apresenta relação direta com a quantidade de clorofila, portanto baixos teores do índice podem ser associados com baixo teor de clorofila [25].

Os índices NDWI (*Normalized Difference Water Index*) e NDWI12 (modified NDWI) tiveram impacto mais significativo na diferenciação entre as fases 2-3. Os índices NDWI e NDWI12, derivados das bandas do infravermelho médio (SWIR1 e SWIR2), são sensíveis às mudanças no conteúdo de água líquida da vegetação, pois estão localizados próxima da região de absorção de água [19].

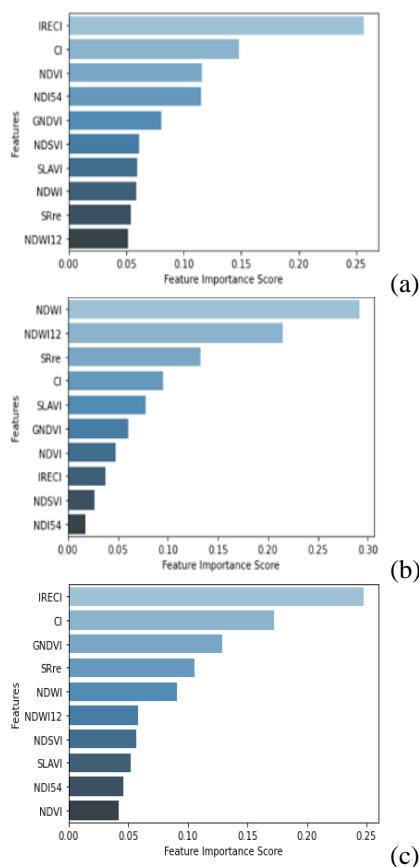


Figura 3. Rankings de índices espectrais relacionados as (a) fases 1 – 2, (b) fases 2 – 3 e (c) fases 3 – 4.

### 3.2 Modelagem dos dados espectrais

As matrizes de confusão são apresentadas na Figura 4 e as análises das classificações feitas através dos cálculos de acurácia, precisão e recall são mostradas na Tabela 2. Nota-se que o modelo desenvolvido para distinção entre as fases 2 e 3 apresentou resultado superior aos demais modelos.

A acurácia e a precisão nas análises 1-2 e 2-3 foram superiores a 95%. Na análise 1-2 houve maior erro associado à classe 2, ou seja, o cultivo estava em estágio emergência, mas foi classificado como estágio vegetativo. Na análise 2-3 verifica-se erro similar entre as classes, com 6054 pixel pertencente à classe reprodutiva sendo classificado como classe vegetativa e 6036 pixels da classe vegetativa sendo classificados como classe reprodutiva.

A precisão do modelo na distinção entre as classes 3-4 foi de 95%, com acurácia e recall de cerca de 93% e 91%, respectivamente. A partir da matriz de confusão pode-se notar que houve maior erro associado à classificação do período de maturação, ou seja, o cultivo estava em período reprodutivo, mas foi classificado como classe de maturação. As datas de transição fenológicas são provenientes diretamente do campo, ou seja, alto nível de detalhamento, enquanto a modelagem recebeu dados de satélite de média resolução espacial e resolução temporal de 5 dias. Portanto, as métricas extraídas de imagens, à nível de pixel, não equivalem diretamente àquelas extraídas do [26]. A agregação da resposta do dossel em célula de grade (pixel) e a observação de campo de plantas individuais introduz incertezas a modelagem [25].




Figura 4. Matrizes de confusão relacionados as (a) fases 1 – 2, (b) fases 2 – 3 e (c) fases 3 – 4 utilizando modelo RF (k = 10)

Análise	Classe	Random Forest (K-Fold = 10)		
		Acurácia (%)	Precisão (%)	Recall (%)
1 vs 2	1	0,96	0,95	0,97
	2		0,97	0,95
2 vs 3	2	0,98	0,98	0,98
	3		0,98	0,98
3 vs 4	3	0,93	0,91	0,95
	4		0,95	0,91

Tabela 2. Resultados das métricas de avaliação da comparação entre as fases sucessivas

## 4. CONCLUSÕES

O estudo forneceu uma metodologia para monitoramento fenológico das áreas de cultivo de algodão usando sensoriamento remoto de média resolução quase em tempo real. Mais pesquisas são necessárias para avaliar o comportamento do método sobre outras áreas algodoeiras, contudo, os resultados indicam que a abordagem tem potencial para ser aplicada no monitoramento do desenvolvimento da cultura do algodão e pode auxiliar em decisões de manejo.

## 5. REFERÊNCIAS

- [1] Associação Brasileira dos Produtores de Algodão [ABRAPA]. 2022. *Algodão no Mundo*. Disponível em: <<https://www.abrapa.com.br/Paginas/dados/algodao-no-mundo.aspx>>. Acesso em: 15 setembro 2022.
- [2] Queiroz, D.M.; Valente, D.S.M.; Pinto, F.A.C.; Borém, A. *Agricultura de Precisão*. 2 ed. Oficina de Textos, São Paulo, São Paulo, Brasil. 2021.
- [3] Beltrão, N.E.M.; Azevedo, D.M.P. *O agronegócio do algodão no Brasil*. 2ed. Embrapa Informação Tecnológica, Brasília, DF, Brasil. 2008.
- [4] Gao, F.; Anderson, M.C.; Zhang, X.; Yang, Z.; Alfieri, J.G.; Kustas, W.P.; Mueller, R.; Johnson, D.M.; Prueger, J.H. Toward mapping crop progress at field scales through fusion of landsat and modis imagery. *Remote Sensing of Environment*, 188:9-25, 2017.
- [5] Liu, L.; Zhang, X.; Yu, Y.; Gao, F.; Yang, Z. Real-Time Monitoring of Crop Phenology in the Midwestern United States Using VIIRS Observations. *Remote Sensing*, 10:2-18, 2018.
- [6] Formaggio, A.R.; Sanches, I.D.A. 2017. Sensoriamento remoto em agricultura. 1ed. Oficina de Textos, São Paulo, São Paulo, Brasil.
- [7] Ponzoni, F.J.; Shimabukuro, Y.E. 2009. Sensoriamento remoto no estudo da vegetação. 1ed. Parêntese editora, São José dos Campos, São Paulo, Brasil.
- [8] Epiphânio, J.C.N.; Novo, E.M.L.M.; Machado, L.A.T. 2010. Espaço. 1ed. Blucher, São Paulo, São Paulo, Brasil.
- [9] Adami, M.; Bernardes, S.; Araia, E.; Freitas, R.M.; Shimabukuro, Y.E.; Espírito-Santo, F.D.B.; Rudorff, B.F.T.; Anderson, L.O. 2018. Seasonality of vegetation types of South America depicted by moderate resolution imaging spectroradiometer (MODIS) time series. *International Journal of Applied Earth Observation and Geoinformation* 69:148-163.
- [10] Begue, A.; Vintrou, E.; Saad, A.; Hiernaux, P. Differences between cropland and rangeland MODIS phenology (start-of-season) in Mali. *International Journal of Applied Earth Observation and Geoinformation*, 31:167-170, 2014.
- [11] Ji, Z.; Pan, Y.; Zhu, X.; Wang, J.; Li, Q. 2021. Prediction of Crop Yield Using Phenological Information Extracted from Remote Sensing Vegetation Index. *Sensors*, 21:1-16, 2021.
- [12] Zhang, X.; Friedl, M.A.; Schaaf, C.B.; Strahler, A.H.; Hodges, J.C.F.; Gao, F.; Reed, B.C.; Huete, A. Monitoring vegetation phenology using MODIS. *Remote Sensing of Environment*, 84:471-475, 2003.
- [13] Beltrão, N.E.M.; Azevedo, D.M.P. *O agronegócio do algodão no Brasil*. 2ed. Embrapa Informação Tecnológica, Brasília, DF, Brasil. 2008.
- [14] Agro Bayer Brasil [BAYER]. 2022. *Desenvolvimento do algodoeiro*. Disponível em: <<https://www.agro.bayer.com.br/mundo-agro/agropedia/desenvolvimento-do-algodoeiro>>. Acesso em: 04 abril 2022.
- [15] Gitelson, A.A.; Gritz, Y.; Merzlyak, M.N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160:271-282, 2003.
- [16] Gitelson, A.A.; Kaufman, Y.J.; Merzlyak, M.N. Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58:289-298, 1996.
- [17] Psomiadis, E.; Dercas, N.; Dalezios, N.R.; Spyropoulos, N.V. Evaluation and cross-comparison of vegetation indices for crop monitoring from sentinel-2 and worldview-2 images. *Remote Sensing for Agriculture, Ecosystems, and Hydrology*, 10421:1-13, 2017.
- [18] Delegido, J.; Vergara, C.; Verrelst, J.; Gandía, S.; Moreno, J. Remote estimation of crop chlorophyll content by means of high-spectral-resolution reflectance techniques. *Agronomy Journal*, 103:1834-1842, 2011.
- [19] Qi, J.; Goodrich, D.; Marsett, R.; Weltz, M. Ranges Improves Satellite-based Information and Land Cover Assessments in Southwest United States. *Eos, Transactions American Geophysical Union*, 83:605-606, 2002.
- [20] Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. 1973. *Monitoring vegetation systems in the great plains with ERTS*. In: Earth Resources Technology Satellite-1 Symposium, Washington, DC, United States, 1973.
- [21] Gao, B. NDWI A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from Space. *Remote Sensing of Environment*, 58:257-266, 1996.
- [22] Lyburner, L.; Beggs, P.J.; Jacobson, C.R. Estimation of Canopy-Average Surface-Specific Leaf Area Using Landsat TM Data. *Photogrammetric Engineering and Remote Sensing*, 66:183-191, 2000.
- [23] Sims, D.; Gamon, J. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81:337-354, 2002.
- [24] James, G.; Witten, D.; Hastie, T.; Tibshirani, R. *An Introduction to Statistical Learning with Application in R*. 2ed. Springer, Nova York, Estados Unidos. 2013.
- [25] Zhang, X., Wang, J., Gao, F., Liu, Y., Schaaf, C., Friedl, M., Yu, Y., Jayavelu, S., Gray, J., Liu, L. Exploration of scaling effects on coarse resolution land surface phenology. *Remote Sensing of Environment*, 190:318-330, 2018.
- [26] Zeng, L.; Wardlow, B.D.; Xiang, D.; Hu, S.; Li, D. A review of vegetation phenological metrics extraction using time-series, multispectral satellite data. *Remote Sensing of Environment*, 237:1-20, 2020.