

ELENIZ APARECIDA DIAS

**CLASSIFICAÇÃO DA PRODUTIVIDADE DE SOJA E AVALIAÇÃO DE GRUPOS
DE MATURAÇÃO POR MEIO DE IMAGENS MULTIESPECTRAIS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Magister Scientiae*.

Orientador: Luiz Alexandre Peternelli

Coorientadores: Felipe Lopes da Silva
Domingos Sárvio Magalhães Valente

**VIÇOSA – MINAS GERAIS
2022**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

D541c
2022
Dias, Eleniz Aparecida, 1993-
Classificação da produtividade de soja e avaliação de
grupos de maturação por meio de imagens multiespectrais /
Eleniz Aparecida Dias. – Viçosa, MG, 2022.
1 dissertação eletrônica (33 f.): il. (algumas color.).

Orientador: Luiz Alexandre Peternelli.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Estatística, 2022.

Referências bibliográficas: f. 29-33.

DOI: <https://doi.org/10.47328/ufvbbt.2023.485>

Modo de acesso: World Wide Web.

1. Soja - Seleção. 2. Soja - Classificação. 3. Soja -
Rendimento. 4. Redes neurais (Computação). 5. *Glycine max*.
I. Peternelli, Luiz Alexandre, 1966-. II. Universidade Federal de
Viçosa. Departamento de Estatística. Programa de
Pós-Graduação em Genética e Melhoramento. III. Título.

CDD 22. ed. 633.342

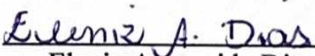
ELENIZ APARECIDA DIAS

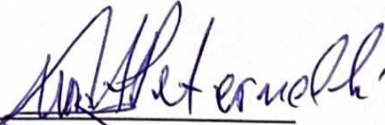
**CLASSIFICAÇÃO DA PRODUTIVIDADE DE SOJA E AVALIAÇÃO DE GRUPOS
DE MATURAÇÃO POR MEIO DE IMAGENS MULTIESPECTRAIS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Magister Scientiae*.

APROVADA: 19 de agosto de 2022

Assentimento:


Eleniz Aparecida Dias
Autora


Luiz Alexandre Peternelli
Orientador

AGRADECIMENTOS

Agradeço primeiramente a DEUS, pela vida, por me dar a força que preciso para não desistir dos meus objetivos e me proporcionar tudo que tenho.

Aos meus pais, Jovita da Mata Dias e Israel Alves Dias, pelo apoio, pelo incentivo, por serem minha base e me ajudarem a superar cada obstáculo em meu caminho. Por todo amor e carinho a mim dedicados. Serei eternamente grata a vocês por tudo que sou e que conquistei até aqui.

Ao meu filho João Pedro, foi por você que decidi fazer o mestrado. Você é minha maior força e o maior motivo da minha felicidade.

A toda minha família, meu irmão, meus tios e primos, que sempre estiveram ao meu lado, me apoiaram, incentivaram e vibram comigo cada conquista.

Ao meu orientador, Luiz Alexandre Peternelli, por toda paciência e compreensão. Por sua dedicação e por se colocar sempre pronto para me ajudar, mesmo em seus momentos de descanso. Por todos os conselhos e ensinamentos compartilhados de forma admirável. Obrigada por me orientar, por ser meu amigo, por me apoiar e acreditar em mim. Muito obrigada por tudo.

Aos meus coorientadores, professor Felipe Lopes da Silva e professor Domingos Sárvio Magalhães Valente, por toda a ajuda durante a realização deste trabalho, pelos ensinamentos e amizade. A contribuição dos senhores foi essencial para a concretização de todas as pesquisas desenvolvidas neste trabalho.

Aos meus amigos do LAPEA, em especial a Tays, Mateus, Gleyner e Wagner, que me ajudaram nas análises. A todos do laboratório por me acolherem, pela amizade, pelas conversas, conselhos e momentos alegres de descontração.

Ao Danilo, pós doutorando do LAPEA. Obrigada por toda atenção, dedicação, por me ajudar sempre que precisei, pelos ensinamentos e pela amizade.

A todos os alunos da graduação e pós-graduação do Programa Soja - UFV, por me acolherem no programa, por me ajudarem a realizar esse trabalho, pelos conhecimentos compartilhados e pela amizade.

Aos amigos que conheci durante o mestrado e aqueles que reencontrei, vocês tornaram essa caminhada mais fácil.

À Universidade Federal de Viçosa (UFV) e ao Programa de Pós-Graduação em Genética e Melhoramento, pela excelência e oportunidade de prosseguir meus estudos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Aos secretários e ao Programa de Pós-graduação em Genética e Melhoramento da Universidade Federal de Viçosa, especialmente o Marco Tulio, por toda atenção, dedicação e serviços prestados durante meu mestrado.

A todos que de alguma forma contribuíram com carinho, atenção, amizade, apoio e incentivo para a conclusão desta importante etapa da minha vida. Muito obrigada!

RESUMO

DIAS, Eleniz Aparecida, M.Sc., Universidade Federal de Viçosa, agosto de 2022. **Classificação da produtividade de soja e avaliação de grupos de maturação por meio de imagens multiespectrais.** Orientador: Luiz Alexandre Peternelli. Coorientadores: Felipe Lopes da Silva e Domingos Sárvio Magalhães Valente.

A participação da soja (*Glycine max* (L.) Merrill) em diversos setores agrícolas e industriais, fazem da cultura um dos principais produtos do agronegócio brasileiro. Tal fato é reflexo do progresso genético sobre a expansão da oleaginosa pelo país nas últimas décadas. Tendo em vista a importância do desenvolvimento de cultivares mais precoces e produtivas este trabalho teve como objetivo avaliar o potencial do uso de imagens multiespectrais obtidas por VANTs para substituir ou simplificar a coleta de dados em campo, além de classificar grupos de maturação e produtividade em plantas de soja, visando auxiliar na seleção de genótipos superiores. O estudo avaliou dois experimentos conduzidos em delineamento de blocos casualizados com três repetições no município de Viçosa, MG. O experimento I contou com 84 populações e os 15 genitores avaliados em um total de 297 parcelas. Para o experimento II foram utilizadas 15 populações e seis genitores, totalizando 63 parcelas. Foram utilizadas 11 imagens, por experimento, obtidas por meio de missões de voo, na altura de 40 m, realizadas durante o ciclo da soja. O modelo de drone utilizado foram o DJI Matrice 100 (DJI Innovations, Shenzhen, China) equipado com a câmera multiespectral MicaSense RedEdge MX (MicaSense, Seattle, WA, EUA). Com base nas bandas espectrais das imagens processadas, foram calculados os índices de vegetação ARVI, CIG, CIRE, CVI, DVI, EVI, GNDVI, LCI, MCARI1, MSR, NDRE, NDVI, NGRDI, PRI, RDVI, RI, RVI, SAVI, SIPI, SR, TVI. Em seguida, cada conjunto de dados de índices por data de voo, foram aplicados na Rede Neural Feed Forward (FFNN). As análises foram realizadas por meio do *software* R para tratamento das imagens e para a construção dos modelos de predição. O modelo baseado nos IVs, obteve precisão e acurácia acima de 60% na classificação de produtividade. Os IVs, calculados a partir dos dados de refletância do dossel, não apresentaram diferenças significativas entre os grupos de maturação que pudessem contribuir para identificar cultivares mais precoces. No entanto, 113 dias após o plantio, entre os estádios R6-R7, os IVs ARVI, NDVI, TVI, SIPI, PRI, RI, RVI, LCI e NGRDI se mostraram mais aptos a identificar diferença entre os grupos de maturação.

Palavras-chave: Índices de vegetação. Modelos de classificação. Redes neurais. *Glycine max*

ABSTRACT

DIAS, Eleniz Aparecida, M.Sc., Universidade Federal de Viçosa, August 2022. **Classification of soybean yield and evaluation of maturation groups using multispectral images.** Advisor: Luiz Alexandre Peternelli. Co-advisors: Felipe Lopes da Silva and Domingos Sárvio Magalhães Valente.

The participation of soybean (*Glycine max* (L.) Merrill) in several agricultural and industrial sectors makes the culture one of the main products of Brazilian agribusiness. This fact is a reflection of the genetic progress on the expansion of the oilseed across the country in recent decades. Considering the importance of developing earlier and more productive cultivars, this study aimed to evaluate the potential of using multispectral images obtained by UAVs to replace or simplify field data collection, in addition to classifying maturation and productivity groups in plants of soy. The study evaluated two experiments carried out in a randomized block design with three replications in the city of Viçosa, MG. Experiment I had 84 populations and 15 parents evaluated in a total of 297 plots. For experiment II, 15 populations and six parents were used, totaling 63 plots. Eleven images were used, per experiment, obtained through flight missions, at a height of 40 m, carried out during the soybean cycle. The drone model used was the DJI Matrice 100 (DJI Innovations, Shenzhen, China) equipped with the MicaSense RedEdge MX multispectral camera (MicaSense, Seattle, WA, USA). Based on the spectral bands of the processed images, the vegetation indices ARVI, CIG, CIRE, CVI, DVI, EVI, GNDVI, LCI, MCARI1, MSR, NDRE, NDVI, NGRDI, PRI, RDVI, RI, RVI were calculated, SAVI, SIPI, SR, TVI. Then, each dataset of indices by date were applied to the Neural Feed Forward Network (FFNN). The analyzes were performed using the R software to process the images and phenotypic data, and to build the prediction models. The model based on IVs obtained precision and accuracy above 60% in the productivity classification. IVs, calculated from canopy reflectance data, did not show significant differences between maturation groups that could contribute to identifying earlier cultivars. However, 113 days after planting, between the R6-R7 stages, the IVs ARVI, NDVI, TVI, SIPI, PRI, RI, RVI, LCI and NGRDI were more able to identify differences between the maturation groups.

Keywords: Vegetation Indexes. Classification models. Neural networks. *Glycine max*

SUMÁRIO

INTRODUÇÃO	8
OBJETIVOS	11
Objetivo Geral	11
Objetivos específicos	12
MATERIAL E MÉTODOS	12
Material Vegetal	12
Obtenção de imagens	13
Análises Estatísticas	18
RESULTADOS E DISCUSSÃO	19
Classificação de produtividade através da FFNN com base em IVs	19
Classificação de maturidade da soja	24
CONCLUSÃO	28
REFERÊNCIAS BIBLIOGRÁFICAS	29

INTRODUÇÃO

A soja é a principal oleaginosa produzida e consumida no mundo e é o principal produto do agronegócio brasileiro (SEIXAS et al., 2020). A produção mundial na safra 21/22 foi de 355,688 milhões de toneladas. O Brasil é o maior produtor mundial da cultura com uma produção estimada de 125,6 milhões de toneladas na última safra, quase 10% menor do que a safra anterior, devido a severa estiagem ocorrida no Sul do país, no final de 2021 (CONAB, 2022).

A maior parte da produção brasileira concentra-se nas Regiões Sul e Centro-Oeste, onde o principal sistema de cultivo é a sucessão soja-milho (SILVA et al., 2022). Com o crescimento do milho de segunda safra, a busca por cultivares que associem menor ciclo de maturação e alta produtividade tem aumentado. Como a soja precoce permanece menos tempo no campo é possível antecipar o plantio da segunda safra, permitindo que o cultivo do milho ocorra em época com menores riscos a períodos de seca e geada (ALLIPRANDINI, 2019). Além disso, cultivares precoces sofrem menor pressão de doenças de final de ciclo na soja, como *Cercospora kikuchii* (crestamento foliar de *Cercospora*) e *Phakopsora pachyrhizi* (ferrugem asiática), responsáveis por reduções consideráveis no rendimento da cultura (FINOTO et al., 2011; TEIXEIRA, 2017).

O ciclo biológico dos genótipos é influenciado principalmente pelo fotoperíodo e pela temperatura. Portanto é necessária atenção à latitude e seus efeitos sobre tais características. A soja é uma planta de dias curtos. Isso significa que ela floresce em fotoperíodos menores que um máximo crítico (SILVA et al., 2017). A sensibilidade ao fotoperíodo varia com a cultivar, isto é, cada cultivar tem seu fotoperíodo crítico, acima do qual o florescimento é atrasado. Em razão disso, a faixa de adaptabilidade de cada cultivar varia à medida que se desloca em direção ao norte ou ao sul (EMBRAPA, 2010).

Existem 13 grupos de maturidade relativa (GMR), estabelecidos mundialmente, que predizem em que faixa de latitude um cultivar apresenta maior adaptabilidade e estabilidade produtiva. Eles são designados 000, 00, 0 e 1 a 10. As cultivares do grupo 000 são cultivadas nas regiões mais próximas aos polos, de alta latitude (cultivares precoces, adaptadas a dias longos) e os cultivares 10 são cultivados próximos a linha do equador (cultivares tardias, adaptadas a dias curtos). No Brasil a classificação inicia no grupo 5, região sul, e vai até o GMR 10, próximo a linha do equador (SEDIYAMA et al., 2015).

Dentro de uma mesma faixa de latitude, a duração total do ciclo da soja (número de dias da emergência até a maturação das vargens) ainda pode ser classificada como superprecoce,

precoce, semiprecoce, médio, semitardio e tardio. Sendo assim, a indicação de um cultivar considerando seu ciclo só deve ser realizada dentro dessa faixa de adaptação, pois em regiões de latitude maior que a considerada, as cultivares apresentam florescimento mais tardio que o normal, e em latitudes menores, as cultivares terão uma maturação mais precoce. O ciclo da espécie varia de aproximadamente 70 a 200 dias, sendo que a maioria dos cultivares adaptados as condições brasileiras variam de 90 a 150 dias (SEDIYAMA, 2009; SEDIYAMA et al., 2015).

Quanto à temperatura, o ideal para seu crescimento e desenvolvimento está em torno de 30°C. A ocorrência de altas temperaturas pode acelerar a maturação, enquanto baixas temperaturas, menores que 13 °C, inibem ou retardam a indução da soja ao florescimento. Conseqüentemente, retardam seu desenvolvimento, e se associadas a períodos chuvosos e alta humidade, na fase de maturação, podem atrasar a colheita (EMBRAPA, 2010; SEDIYAMA et al., 2015).

A adaptabilidade da soja a uma ampla faixa de latitudes se deve à variação natural de genes e locos de características quantitativas (QTL) que controlam o florescimento (KONG et al., 2014). Até o presente momento, 12 genes principais foram identificados controlando o tempo de floração e maturidade em soja: E1 e E2 (BERNARD, 1971), E3 (BUZZELL, 1971), E4 (BUZZEL & VOLDENG, 1980), E5 (MCBLAIN & BERNARD, 1987), E6 (BONATO & VELLO, 1999), E7 (COBER et al., 2001), E8 (COBER et al., 2010), E9 (KONG et al., 2014), E10 (SAMANFAR et al., 2017), E11 (WANG et al., 2019) e J (RAY et al., 1995).

Em relação a produtividade, trata-se de uma característica essencial para qualquer cultura agrícola, fundamental para o desempenho econômico no campo. A maior produtividade da soja, não só aumenta a lucratividade da cultura, como também diminui a necessidade de abrir novas áreas para plantio, o que contribui para a preservação do meio ambiente (NETO, 2017). No entanto, a produtividade é um caráter quantitativo controlado por vários genes, que sofrem alto efeito ambiental, ou seja, ela é afetada pelo ambiente, pelos componentes genéticos e pela interação entre ambos. Isso dificulta a avaliação da capacidade de produção e a seleção dos melhores genótipos (POLIZEL, 2013).

A caracterização da precocidade e produtividade é uma tarefa dispendiosa, que exige tempo e mão de obra (FERREIRA, 2020). Nesse contexto, o uso de imagens aéreas tem se mostrado uma ferramenta de elevado potencial na otimização desse processo. É possível obter imagens com alta precisão e rendimento para estimar parâmetros bióticos e abióticos por meio de veículo aéreo não tripulado (VANT), fornecendo informações confiáveis sobre o estado da lavoura. Isso pode ajudar na avaliação do desempenho de genótipos, práticas de manejo e impactos de fatores bióticos e abióticos (FRANCHINI et al., 2018).

Convencionalmente, as datas de maturidade das linhagens são estimadas através da classificação visual das vagens por especialistas, baseada na senescência. No entanto, a classificação visual é subjetiva pela estimativa humana, bem como trabalhosa e demorada (ZHOU et al., 2019). Com a planta se aproximando da maturação plena, as vagens tornam-se marrons, o que pode resultar em mudanças substanciais na refletância espectral (FEHR, 1971). Logo, é possível quantificar o nível de maturidade da planta usando as combinações de refletância espectral em determinadas bandas de onda que são muito sensíveis às características do dossel da cultura (ZHOU et al., 2019).

Sabe-se que as propriedades espectrais da vegetação são específicas do genótipo e influenciadas pela anatomia, morfologia e fisiologia das plantas. Assim, essas propriedades espectrais podem ser usadas para a seleção de genótipos de plantas com diferentes potenciais agrônomicos (YOOSEFZADEH-NAJAFABADI et al., 2021). Uma forma de se inferir sobre as condições da cultura a partir de imagens digitais é por meio do uso de índices de vegetação (IV). Os índices de vegetação são operações matemáticas que utilizam a refletância de duas ou mais bandas do espectro eletromagnético de cada alvo, com o objetivo de avaliar alguma propriedade da vegetação (GIOVOS et al., 2021). Além disso, eles podem ser usados para segmentar alvos de interesse, como solo exposto, água e a própria vegetação (BERNARDI et al., 2014).

A previsão de produtividade de grãos em espécies agrícolas usando IVs é bastante difundida e estudada. SCHULZ et al. (2021) demonstraram que a produtividade da soja está ligada à altura de planta, zona de produção na haste, ao índice NDVI e índice de folhas verdes (GLI). TRINDADE et al. (2019) avaliaram relações espectrais e temporais dos índices NDVI e EVI do sensor MODIS com a produtividade da soja e atributos do solo e concluíram que o EVI nos estádios R1, R2 e R3 (início do ciclo reprodutivo) gerou os melhores modelos de previsão dos atributos do solo e o NDVI no estágio R2 para previsão da produtividade.

SILVA et al. (2020) analisaram quais IVs podem ser usados para prever a produtividade de grãos de soja usando VANT e sensor multiespectral. Seus resultados mostraram que o NDVI se destacou em relação aos demais índices estudados, onde as regiões com os maiores valores do índice obtiveram a maior produtividade observada em campo.

REZNICK et al. (2021) obtiveram bons resultados em um estudo da relação do NDVI com a produtividade de grãos e teores de proteína e glúten da farinha de trigo. Segundo os autores, o NDVI obtido pelo sensor óptico ativo permite a estimativa de campo rápida e aceitável do rendimento de grãos e da concentração de proteína e glúten na farinha, permitindo gerar modelos de estimativa dessas variáveis para cada cultivar.

ZHANG et al. (2019) desenvolveram um modelo dinâmico de previsão de produtividade de grãos com base nos índices NDVI, NDRE, RVI e RERVI, no qual o índice NDRE foi considerado o mais estável dentre os índices e adequado para a análise de Nitrogênio do arroz em casca. O modelo baseado em NDRE ainda previu com precisão as diferenças entre os tratamentos e os níveis finais de rendimento de grãos. Assim, criaram um modelo capaz de prever efetivamente o rendimento de grãos no alongamento do caule e nos estágios de emborrachamento, fornecendo dados nutricionais de N da cultura em tempo real para o manejo da cobertura de fertilizantes nitrogenados na produção de arroz, com precisão geral superior a 80%.

Muitos pesquisadores utilizam algoritmos de aprendizado de máquina (ML) para analisar informações espectrais e biofísicas coletadas por meio de índices de vegetação, buscando novos métodos de melhoramento baseados em modelos capazes de prever parâmetros agrônômicos. Esses métodos empregam técnicas estatísticas avançadas para modelar funções não lineares complexas entre informações espectrais e características biofísicas (YOOSEFZADEH-NAJAFABADI et al., 2021; ALABI et al., 2022).

O aprendizado de máquina, é uma abordagem prática que pode fornecer uma melhor previsão de produtividade com base em dados das características dos genótipos. É possível determinar padrões e correlações de conjuntos de dados, por meio de algoritmos de ML (VAN KLOMPENBURG et al., 2020). Um exemplo de ML é a rede neural artificial, um algoritmo inspirado no funcionamento do cérebro humano, através da simulação de seus neurônios e de suas ligações, que pode ser aplicada em problemas complexos de diversas áreas. (KOPILER et al., 2019).

Frente a essas observações, este trabalho tem como objetivo avaliar o uso da Rede Neural Feed Forward (LAUDINE, 2015) para classificar os genótipos de soja em grupos de produtividade, por meio de IVs, bem como classificá-los em grupos de maturação, a fim de fornecer uma ferramenta que possa auxiliar pesquisadores na tomada de decisões.

OBJETIVOS

Objetivo Geral

Avaliar o potencial do uso de imagens multiespectrais obtidas por VANTs para substituir ou simplificar a coleta de dados em campo, além de classificar grupos de maturação e produtividade em plantas de soja, com o intuito de auxiliar na seleção de genótipos superiores.

Objetivos específicos

- Avaliar o uso de redes neurais para a classificação de linhagem em grupos de produtividade a partir de dados de imagens.
- Identificar o melhor período para classificação de grupos de maturação e de produtividade da soja, quanto aos índices de vegetação obtidos por imagens coletadas em diferentes datas.

MATERIAL E MÉTODOS

Material Vegetal

As progênies avaliadas no presente estudo são da geração F₃. Foram utilizados dois experimentos, conduzidos em delineamentos de blocos casualizados com três repetições no município de Viçosa, MG.

No experimento I, 84 populações F₃ de soja e seus respectivos genitores foram avaliadas em um total de 297 parcelas. O experimento II contou com 15 populações e seis genitores, totalizando 63 parcelas. Cada parcela continha 36 sementes distribuídas em linha única de 2,5 m e espaçamento entre as linhas de 0,5 m.

As características agrônômicas avaliadas durante o cultivo e utilizadas como variáveis respostas nas análises foram a data de maturação, determinada quando 50% das plantas da parcela estavam em R8, e a produção, correspondente ao peso em gramas de grãos por parcela.

A Figura 1-A mostra o esquema de plantio dos experimentos, no qual as parcelas do experimento I estão representadas pela cor cinza, as do experimento II pela cor rosa e em amarelo estão as bordas. A Figura 1-B corresponde à imagem aérea da área, no dia 10 de março de 2021, com os polígonos determinando a área das parcelas.

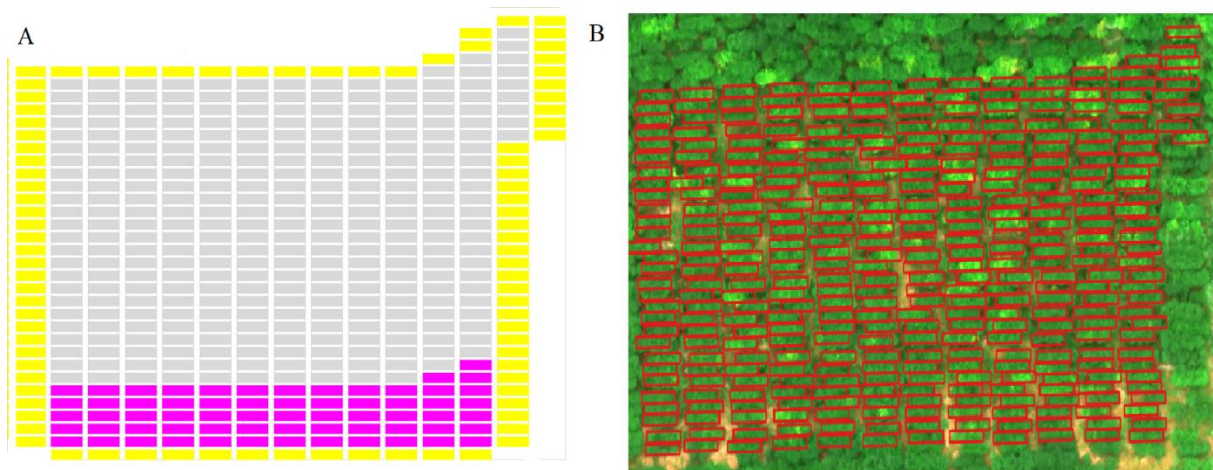


Figura 1. Croqui da área experimental (A). Imagem aérea do dia 10/03/21 com polígonos representando as parcelas (B).

Obtenção de imagens

Para cada experimento foram utilizadas 11 imagens, obtidas por meio de missões de voo, na altura de 40 m, realizadas uma vez por semana durante o ciclo da soja. Todos os voos foram feitos em condições estáveis de luz ambiente por volta de 12h00, utilizando um plano de voo previamente definido no software Precision Flight.

O modelo de drone utilizado foi o DJI Matrice 100 (DJI Innovations, Shenzhen, China) equipado com a câmera multiespectral MicaSense RedEdge MX (MicaSense, Seattle, WA, EUA). A câmera multiespectral possui cinco sensores, os quais fornecem informações nas bandas: 475 nm \pm 20 nm (Azul), 560 nm \pm 20 nm (Verde), 668 nm \pm 10 nm (Vermelho), 717 nm \pm 10 nm (RedEdge) e 840 nm \pm 40 nm (NIR).

As imagens foram processadas no software Agisoft TM MetaShape (versão 1.5.3, Agisoft LLC, St. Petersburg, Russia). A calibração radiométrica de todas as bandas da câmera MicaSense foi realizada usando imagens do painel de calibração, fornecido pelo fabricante, e os fatores de correção apropriados foram extraídos do próprio painel de calibração de referência.

Para georreferenciar as imagens do drone, pontos de controle de solo (GCPs) foram colocados ao longo da área de estudo. As coordenadas dos GCPs foram obtidas usando um receptor topográfico GNSS (Global Navigation Satellite System), modelo Trimble ProXT (Trimble Inc., Estados Unidos).

A partir das imagens processadas, foram gerados os ortomosaicos de cada imagem, para cada ensaio. Feito isso, foram criados polígonos englobando a área útil de cada parcela do estudo por vetorização manual, utilizando o software QGIS. Após o processamento no QGIS,

cada polígono foi transformado em uma imagem de recorte independente, da qual obteve-se as bandas do azul (B), verde (G), vermelho (R), *RedEdge* (RE) e infravermelho próximo (NIR). Com base nas bandas espectrais foram calculados os índices de vegetação: ARVI, CIG, CIRE, CVI, DVI, EVI, GNDVI, LCI, MCARI1, MSR, NDRE, NDVI, NGRDI, PRI, RDVI, RI, RVI, SAVI, SIPI, SR, TVI (Tabela 3), utilizados pela Rede Neural para classificar a produtividade.

Tabela 1. Relação dos índices de vegetação calculados pelo uso do sensor multiespectral

Índice de Vegetação	Equação	Finalidade	Referência
Índice de Vegetação Atmosfericamente Resistente	$ARVI = \frac{NIR - (Red - (Blue - Red))}{NIR + (Red - (Blue - Red))}$	Estima a fração de vegetação em uma cena com baixa sensibilidade aos efeitos atmosféricos.	Kaufman, Y. e D. Tanre. (1992)
Índice de clorofila verde	$CIG = \left(\frac{NIR}{Green} \right) - 1$	Estima IAF e biomassa foliar verde usando refletâncias no verde em torno de 550 nm.	Gitelson et al. (2003)
Índice de clorofila RedEdge	$CIRE = \left(\frac{NIR}{RedEdge} \right) - 1$	Estima IAF e biomassa foliar verde usando refletâncias na borda vermelha perto de 700 nm.	Gitelson et al. (2003)
Índice de vegetação de clorofila	$CVI = NIR * \frac{Red}{Green^2}$	Um IV de banda larga com maior sensibilidade ao teor de clorofila foliar e insensível à variação do IAF.	Vincini et al. (2007)
Índice de vegetação por diferença	$DVI = NIR - Red$	Estima a biomassa fotossinteticamente ativa. Distingue entre solo e vegetação, mas não leva em conta a diferença entre refletância e radiância causada por efeitos atmosféricos ou sombras. É superior ao NDVI para baixas coberturas vegetais.	Richardson, A. J., & Wiegand, C. L. (1977)
Índice de Vegetação Melhorado	$EVI = 2,5 * \frac{(NIR - Red)}{(NIR + 6 * Red - 7,5 * Blue + 1)}$	Uma melhoria em relação ao NDVI, sendo mais útil em regiões de alto IAF onde o NDVI pode saturar. Usa a região de refletância azul para corrigir os sinais de fundo do solo e reduzir as influências atmosféricas, incluindo a dispersão de aerossóis.	Huete et al. (1997)
Índice de vegetação pela diferença normalizada verde	$GNDVI = \frac{NIR - Green}{NIR + Green}$	Estima a vegetação verde. Este índice é mais sensível à concentração de clorofila do que o NDVI.	Gitelson et al. (1996)
Índice de Clorofila Foliar	$LCI = \frac{NIR - RedEdge}{NIR - Red}$	Estima o teor de clorofila em plantas altas, sensíveis à variação na refletância causada pela absorção de clorofila.	Datt, Bisun. (1999)
Primeiro Índice de Razão de Absorção de Clorofila Modificado	$MCARI1 = 1,2 * (2,5 * (NIR - Red) - 1,3 * (NIR - Green))$	Prediz o índice de área foliar verde (IAF). Incorpora um fator de ajuste do solo, preservando a sensibilidade ao IAF e a resistência à influência da clorofila.	Haboudane, D. et al. (2004)
Razão Simples Modificada	$MSR = \frac{\frac{NIR}{Red} - 1}{\sqrt{\frac{NIR}{Red} + 1}}$	Esse índice foi desenvolvido como uma melhoria em relação ao RDVI, combinando a razão simples na fórmula. O resultado é o aumento da sensibilidade aos parâmetros biofísicos da vegetação.	Chen, J. (1996)

Índice de vegetação pela diferença normalizada à transição do vermelho (<i>Red-edge</i>)	$NDRE = \frac{(NIR - RedEdge)}{(NIR + RedEdge)}$	Avalia o teor de clorofila nas plantas, ele não satura tão facilmente quanto o NDVI. Indicado para detecção precoce de estresse e monitoramento do crescimento.	Gitelson e Merzlyak (1994); Barnes et al., (2000)
Índice de vegetação pela diferença normalizada	$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$	Indica o estado e a quantidade de cobertura vegetal verde. Sua fórmula e o uso das regiões de maior absorção e refletância da clorofila o tornam robusto em uma ampla gama de condições. Pode, no entanto, saturar em condições de vegetação densa quando o índice de área foliar se torna alto.	Rouse et al. (1973)
Índice de diferença verde-vermelho normalizado	$NGRDI = \frac{Green - Red}{Green + Red}$	Capaz de quantificar a taxa fotossintética máxima da folha melhor do que NDVI e EVI.	Tucker (1979)
Índice de refletância fotoquímica	$PRI = \frac{Blue - Green}{Blue + Green}$	Sensível a mudanças nos pigmentos carotenoides (particularmente pigmentos de xantofila) na folhagem viva. Indica a eficiência do uso da luz fotossintética ou da taxa de absorção de dióxido de carbono pela folhagem por unidade de energia absorvida. Utilizado em estudos de produtividade e estresse da vegetação.	Gamon et al. (1992)
Índice de Vegetação por Diferença Renormalizada	$RDVI = \frac{NIR - Red}{\sqrt{NIR + Red}}$	Assim como o NDVI, é usado para destacar a vegetação saudável. É insensível aos efeitos da geometria de visualização do solo e do sol.	Rougean & Breon, (1995)
Índice de vermelhidão	$RI = \frac{Red - Green}{Red + Green}$	Utilizado para corrigir o “ruído do solo” de outros IVs, aumentando a sensibilidade dos mesmos.	Escadafal, R. e Huete, A. (1991)
Índice de vegetação de razão	$RVI = \frac{Red}{NIR}$	Indica o estado e a quantidade de cobertura vegetal verde.	Birth e McVey (1968)
Índice de vegetação ajustado ao solo	$SAVI = \frac{1,5 * (NIR - Red)}{0,5 + NIR + Red}$	Semelhante ao NDVI, mas suprime os efeitos dos pixels do solo. Assim, é melhor usado em áreas com vegetação relativamente esparsa onde o solo é visível através do dossel.	Huete (1988)
Índice de Pigmentos Independentes Estruturais	$SIPI = \frac{NIR - Blue}{NIR + Red}$	Fornecer uma medida da eficiência do uso da luz pela vegetação para a fotossíntese. Acredita-se que aumentos no	Penuelas et al. (1995)

		SIPI indiquem aumento do estresse do dossel (pigmento carotenóide).	
Razão Simples	$SR = \frac{NIR}{Red}$	Estima a biomassa fotossinteticamente ativa. Assim como o NDVI, ele pode saturar em vegetação densa.	Jordan (1969)
Índice de Vegetação Triangular	$TVI = \frac{120*(NIR-Green)-200*(Red-Green)}{2}$	Sensível ao verde da planta. Usado para estimar IAF verde, sua sensibilidade à clorofila aumenta com o aumento da densidade do dossel.	Broge, N. e E. Leblanc (2001)

Blue: reflectância na faixa do azul; Green: reflectância na faixa do verde; NIR: reflectância na faixa do infravermelho próximo; Red: reflectância na faixa do vermelho; RedEdge: reflectância na faixa de transição do vermelho.

Analises Estatísticas

A partir das imagens obtidas em cada voo, para cada experimento, com a câmera multiespectral, foram determinados os índices de vegetação (Tabela 3). Posteriormente aplicou-se a análise descritiva destes índices por meio de gráficos. O objetivo deste passo é avaliar comportamentos semelhantes tanto na forma quanto na escala dos índices associados às datas de voo.

Após o cálculo dos IVs médios, cada conjunto de dados de índices, por data, foram aplicados na Rede Neural Feed Forward (FFNN). Nesta arquitetura de rede os neurônios são totalmente conectados às camadas consecutivas, não havendo conexões para trás ou saltos de camadas (LAUDINE, 2015).

Para a classificação quanto a produtividade, foram avaliadas uma FFNN para cada reamostragem nos 11 dias de voo por experimento. Para cada rede testou-se a utilização de 2 a 20 neurônios em uma única camada intermediária e número máximo de iterações igual a 15 mil.

A diferença na maturação entre a cultivar mais precoce e mais tardia dos dois experimentos foi de apenas 6 dias. Por ser uma discrepância pequena, realizou-se apenas uma análise gráfica do experimento I. Assim a FFNN foi utilizada somente na classificação da produtividade.

Para a aplicação da FFNN, os índices foram divididos em duas classes em relação a produtividade média de todas as parcelas avaliadas. Para cada conjunto de dados, foram realizadas 40 amostras aleatórias, e em cada amostragem, o conjunto de dados foi dividido na proporção 70:30 para treinamento e validação da rede. Com a aplicação desta metodologia, gráficos em boxplot foram utilizados para as métricas de avaliação (SOCOLOVA et al. 2006) da FFNN: acurácia, sensibilidade, especificidade e precisão.

A acurácia representa a taxa em que a predição do algoritmo de classificação foi correta, seja para classe positiva quanto para negativa:

$$acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

A sensibilidade corresponde à proporção de predições verdadeiras positivas em relação a todos valores reais positivos. Esta métrica mostra quão boas foram as previsões positivas do modelo:

$$\text{sensibilidade} = \frac{VP}{VP + FN}$$

A especificidade equivale a proporção de predições negativas que foram classificadas corretamente:

$$\text{especificidade} = \frac{VN}{VN + FP}$$

As análises foram realizadas por meio do *software* R para tratamento das imagens e dados fenotípicos, e para a construção dos modelos de predição. As análises e processamento dos dados foram conduzidos no Laboratório para Análises e Pesquisas em Estatística Aplicada (LAPEA, www.lapea.ufv.br) do Departamento de Estatística/UFV, pertencente à Rede de Pesquisa em Biometria e Estatística da UFV (BIODATA-UFV).

RESULTADOS E DISCUSSÃO

Classificação de produtividade através da FFNN com base em IVs

Para cada imagem determinou-se os valores médios dos índices de vegetação por parcela. Posteriormente, procedeu-se à análise gráfica dos índices em função da média das parcelas nas imagens obtidas ao longo do ciclo da soja.

Com o objetivo de compreender melhor o comportamento inesperado de alguns índices, foram incluídas informações sobre a variação da temperatura ao longo do ciclo da soja nos gráficos. Esses dados foram obtidos do site do Instituto Nacional de Meteorologia, que disponibiliza informações da estação meteorológica digital de Viçosa, local onde os experimentos foram realizados.

Ambos os ensaios tiveram comportamentos semelhantes dos IVs, de modo que apenas os gráficos referentes ao experimento I foram apresentados (Figuras 1 e 2). A análise gráfica mostrou um comportamento semelhante de alguns índices, que foram agrupados por similaridade nos gráficos.

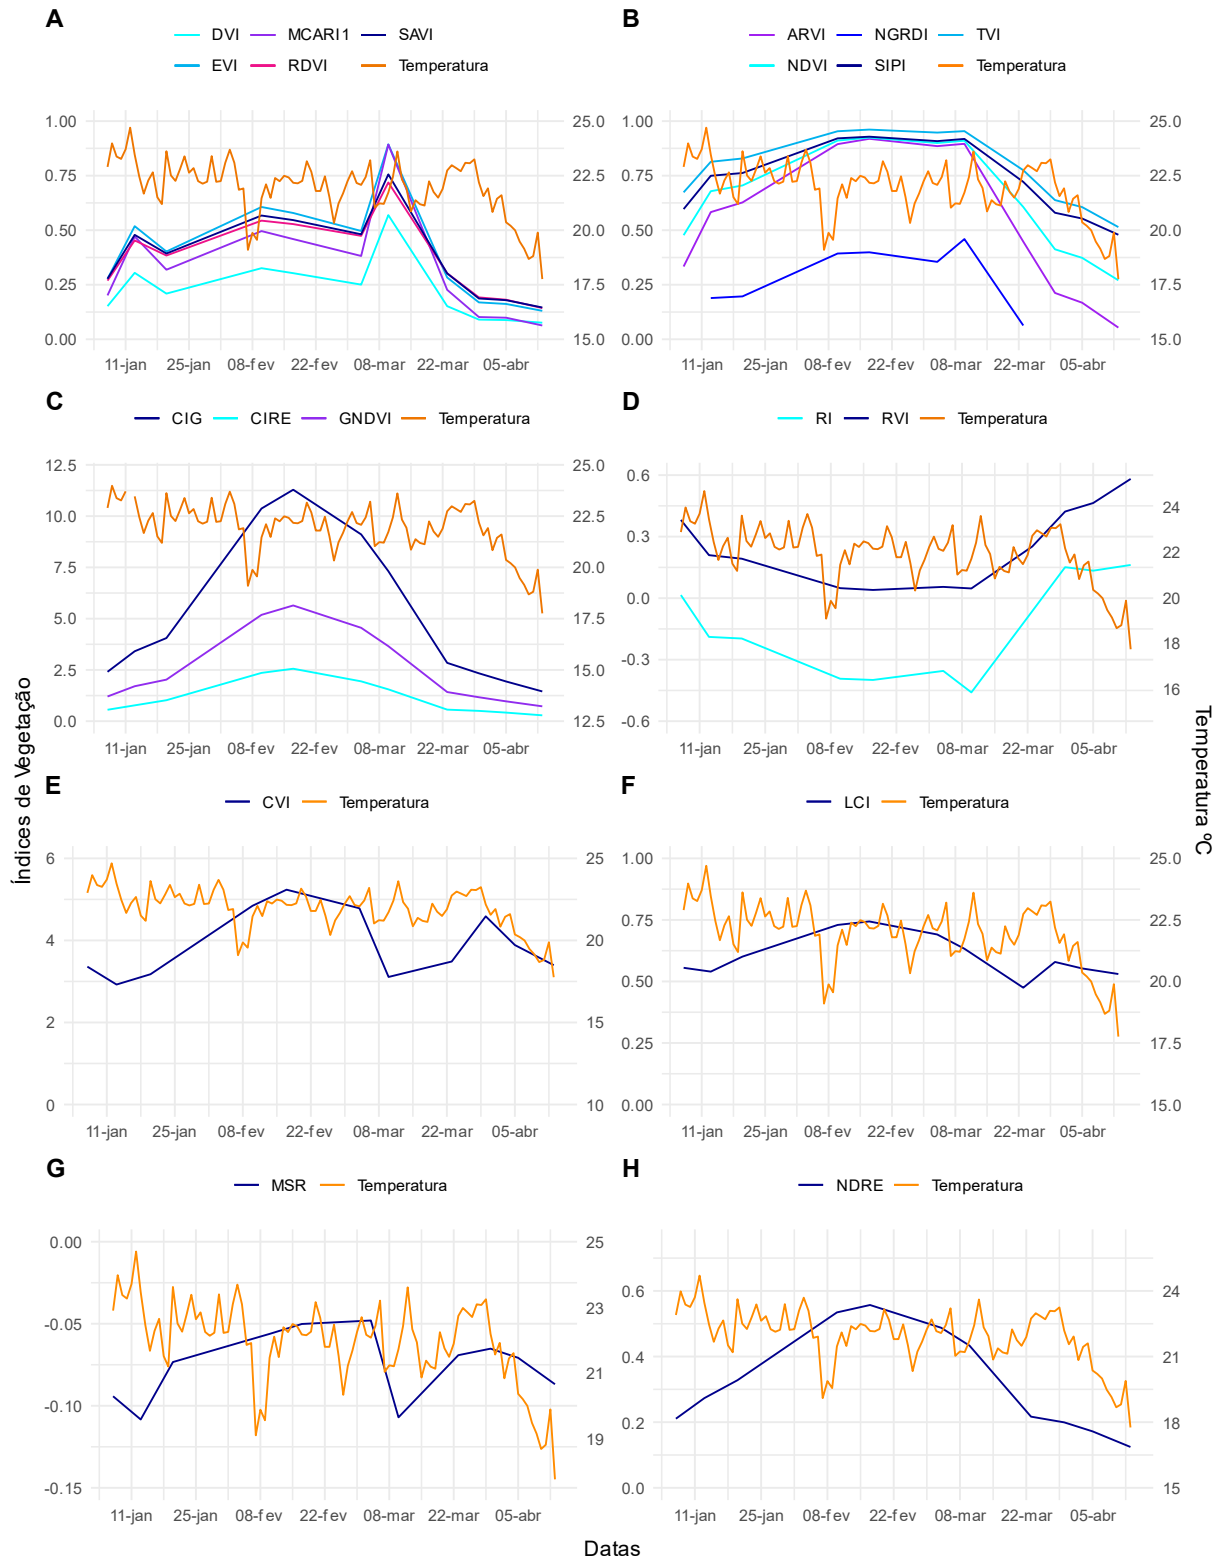


Figura 1– Avaliação gráfica temporal dos índices no decorrer dos 11 dias de voo. No eixo vertical, à esquerda tem-se a variação dos índices de vegetação, descritos acima de cada gráfico. No eixo vertical à direita tem-se a variação da temperatura ao longo do ciclo da soja. As linhas correspondentes aos índices, representam as médias das parcelas avaliadas em cada data de voo para o experimento I.

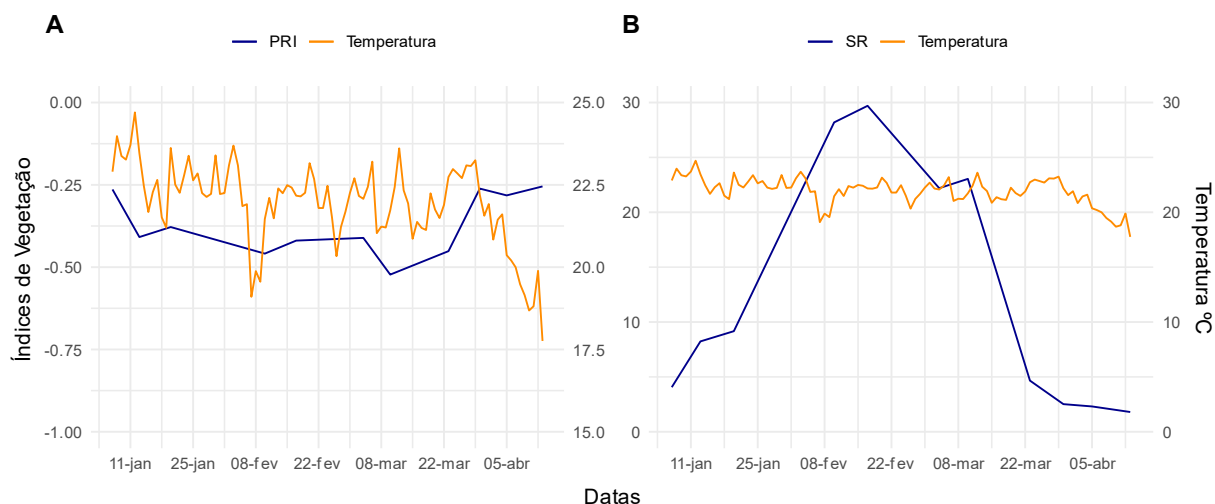


Figura 2 – Avaliação gráfica temporal dos índices no decorrer dos 11 dias de voo. No eixo vertical, à esquerda tem-se a variação dos índices de vegetação, descritos acima de cada gráfico. No eixo vertical à direita tem-se a variação da temperatura ao longo do ciclo da soja. As linhas correspondentes aos índices, representam as médias das parcelas avaliadas em cada data de voo para o experimento I.

Para todos os índices foram encontrados valores que indicam pouca biomassa, ou maior estresse no início e final do ciclo. Esse tipo de resultado já era esperado, posto que, no início do ciclo há pouca biomassa e o solo encontra-se mais evidente nas imagens, enquanto que no final do ciclo as plantas encontravam-se maduras, apresentando cor amarronzada. Nas datas em que o dossel se apresentava fechado ou próximo disso, os IVs tiveram picos, ou quedas, de acordo com as características de variação de cada índice em particular.

Embora os índices de vegetação possuam fórmulas de cálculo distintas, eles têm em comum fornecer informações sobre biomassa, área foliar e saúde da planta (HATFIELD et al., 2019). Eles são sensíveis às propriedades ópticas das plantas, como a absorção da clorofila e a refletância da vegetação e do solo, conseqüentemente, seus valores aumentam à medida que a quantidade de biomassa e a densidade vegetativa aumentam, como pode ser observado nos gráficos no período de 8 de fevereiro a 10 de março. Além disso, esses índices de vegetação podem ser afetados por fatores ambientais comuns, como a cobertura de nuvens, a qualidade dos dados de sensoriamento remoto, a iluminação, a umidade, a temperatura e a presença de solo exposto (FORMAGGIO e SANCHES, 2017). Logo, a semelhança nos comportamentos dos IVs apresentados na Figura 1 (A, B, C e D), pode ser devida a sensibilidade às propriedades ópticas das plantas e à forma como respondem às mudanças na vegetação e às condições ambientais.

Os índices CIG, CIRE, CVI, GNDVI e LCI são usados para avaliar o conteúdo de clorofila nas folhas de diferentes espécies de plantas (KURBANOV e ZAKHAROVA, 2020; TA et al., 2021). O Índice CIG é usado para avaliar o teor de clorofila a e b nas folhas, o estado

dos nutrientes da planta, processos de envelhecimento e a presença de estresses bióticos. Seus valores podem ser maiores ou iguais a -1. Se a vegetação verde com alto teor de clorofila está nas folhas, então o valor do índice é maior que 4, o que pode ser observado no gráfico E. Por exemplo, em soja, tais indicadores são alcançados nas fases de floração e formação de frutos. CVI é indicado para avaliar o nível de clorofila no início estágio vegetativo. O GNDVI pode ser usado para avaliação do envelhecimento e murcha da vegetação, na ausência de dados do canal RedEdge (KURBANOV e ZAKHAROVA, 2020).

Os IVs ARVI, EVI, MCARI, MSR, NDRE, NDVI, NGRDI, RDVI, RVI, SAVI, SR são utilizados pelos pesquisadores como indicadores de biomassa verde (TAYADE et al., 2022; OLIVEIRA; 2021; RANJAN et al., 2019; SOUZA, 2018; XUE e SU, 2017). Com base nos gráficos, é possível observar um aumento na biomassa vegetal até aproximadamente o dia 10 de março. Por ser um índice bastante robusto, o NDVI é aplicável em uma vasta gama de situações. No entanto, este índice pode ficar saturado em regiões de vegetação densa com um alto índice de área foliar, atingindo um valor máximo invariante, mesmo havendo diferença nas características da vegetação (XUE e SU, 2017).

O índice de vegetação PRI foi desenvolvido como um método para avaliar remotamente a eficiência fotossintética usando reflectância de banda estreita. Esse índice é aplicado em análises de estresse e produtividade da vegetação antes da senescência. Seus valores variam de -1 a 1 (GAMON et al., 1992). Outro índice também empregado em avaliações da eficiência do uso da luz é o SIPI. Os valores desse índice variam de 0 a 2 e seus intervalos comuns para vegetação verde são de 0,8 a 1,8 (KUREEL et al., 2022).

Para uma avaliação abrangente das culturas durante todo o ciclo, é eficaz usar vários índices de vegetação, dependendo do estágio da planta, pesquisas, objetivos e recursos da câmera. Caso seja necessária uma avaliação rápida da densidade da cobertura vegetal, recomenda-se utilizar o RVI. Durante toda a estação de crescimento, é racional usar índices resistentes à poluição atmosférica por aerossol e aos efeitos da cobertura do solo: EVI, NDRE, CIG e MCARI. Nos estágios iniciais da planta, com vegetação esparsa e uma grande influência da reflexão do solo pode-se utilizar o CVI. Com uma densidade de vegetação de 20-80%, NDVI e ARVI são ideais. No meio do desenvolvimento do ciclo, com um alto nível de atividade fotossintética e a necessidade de diagnóstico precoce de doenças, o SIPI é o mais diferenciado e sensível às mudanças da cultura. Quando as plantas estão maduras, prontas para a colheita e murchando, é aconselhável usar o GNDVI (KURBANOV e ZAKHAROVA, 2020).

Após o cálculo dos IVs médios, os dados foram aplicados à FFNN. O quantitativo de neurônio utilizado e demais parâmetros das redes foram definidos pelas métricas de avaliação: acurácia (Figura3), especificidade (Figura 4), sensibilidade (Figura 5).




Figura 3– Variabilidade temporal da acurácia para os dois experimentos instalados. A linha tracejada indica a acurácia em 0,5.




Figura 4 - Variabilidade temporal da especificidade para os dois experimentos instalados A linha tracejada indica a especificidade em 0,5.




Figura 5 – Variabilidade temporal da sensibilidade para os dois experimentos instalados. A linha tracejada indica a sensibilidade em 0,5.

No dia 07 de janeiro de 2021, 38 dias após o plantio, as plantas ainda estavam pequenas. As parcelas se apresentavam com pouca cobertura foliar e muito solo exposto. Logo os índices de vegetação apresentaram valores correspondentes a baixo teor de verde. O modelo apresentou alta acurácia e especificidade nessa data, acima de 60%. Isso significa que o modelo foi eficiente em classificar o que era pouco produtivo corretamente. Também foi obtida boa acurácia e sensibilidade no dia 10 de março de 2021, cem dias após o plantio, quando as plantas provavelmente encontravam-se acima do estágio R5, com uma mediana acima de 0,6 para ambos os ensaios. Logo, o modelo foi capaz de classificar mais de 60% das cultivares mais produtivas sem erros. Os IVs utilizados realçam o verde da vegetação, o teor de clorofila ou o estresse. Nessa data, o dossel encontrava-se fechado ou próximo disso. Sabe-se que a quantidade de biomassa tem alta correlação com a produtividade. Possivelmente, o motivo da acurácia ter sido boa no dia 10 de março está relacionado ao fato de que nesse período as folhas das plantas estavam quase ou completamente desenvolvidas, resultando em maiores valores na maioria dos IVs, e também na acurácia.

Classificação de maturidade da soja

Realizou-se a análise gráfica do comportamento dos índices de vegetação ao longo do ciclo da cultura, com o objetivo de identificar os melhores índices para avaliar maturação. Todas as parcelas do experimento I tiveram maturidade acima de 119 dias. Segundo Nepomuceno et

al. (2008), para Minas Gerais, os grupos de maturação são: semiprecoce (101 a 110 dias); médio (111 a 125 dias); semitardio (125 a 145 dias); tardio (>145 dias). Logo todas as parcelas do ensaio possuem ciclo médio ou acima. Dessa forma, optou-se por classificar os grupos de acordo com a média de ciclo das cultivares comerciais, tomadas como testemunhas neste trabalho. As parcelas com ciclos abaixo de 122 dias (média das testemunhas) foram classificadas como GM1, e aquelas de ciclos superior a 122 dias foram chamadas GM2. (Figuras 6, 7 e 8).

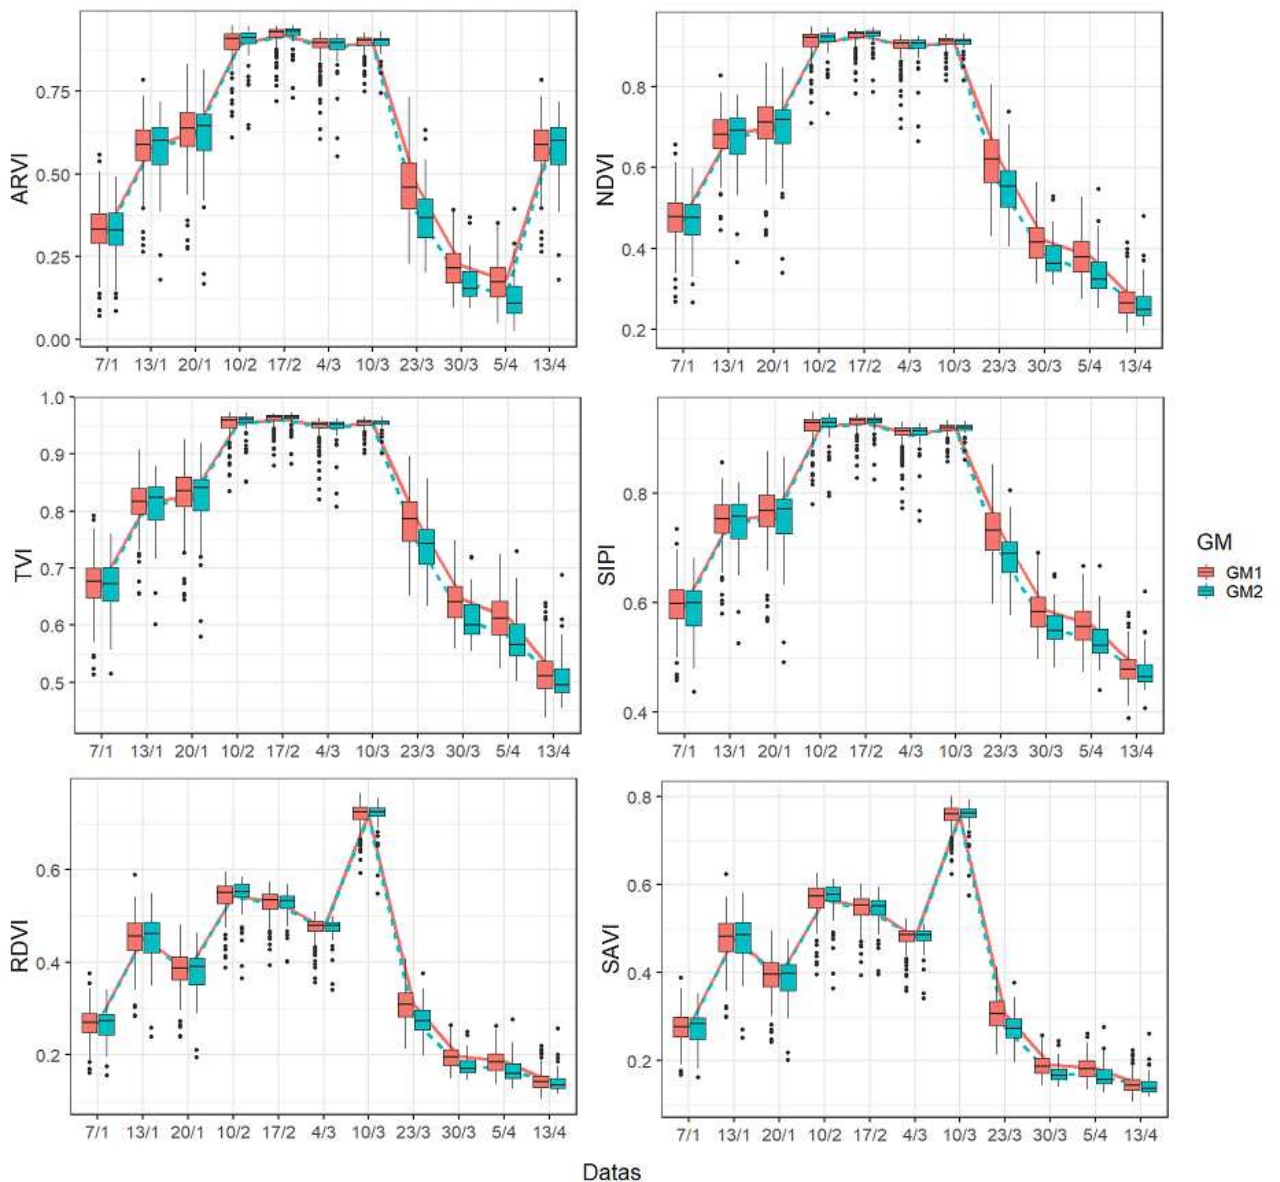


Figura 6. Avaliação gráfica temporal dos índices ARVI, NDVI, TVI, SIPI, RDVI e SAVI no decorrer dos 11 dias de voo. Os pontos em vermelho representam a média do Grupo de maturação 1 (GM1) e em azul representam as médias do GM2, avaliados em cada data de voo para o experimento I.

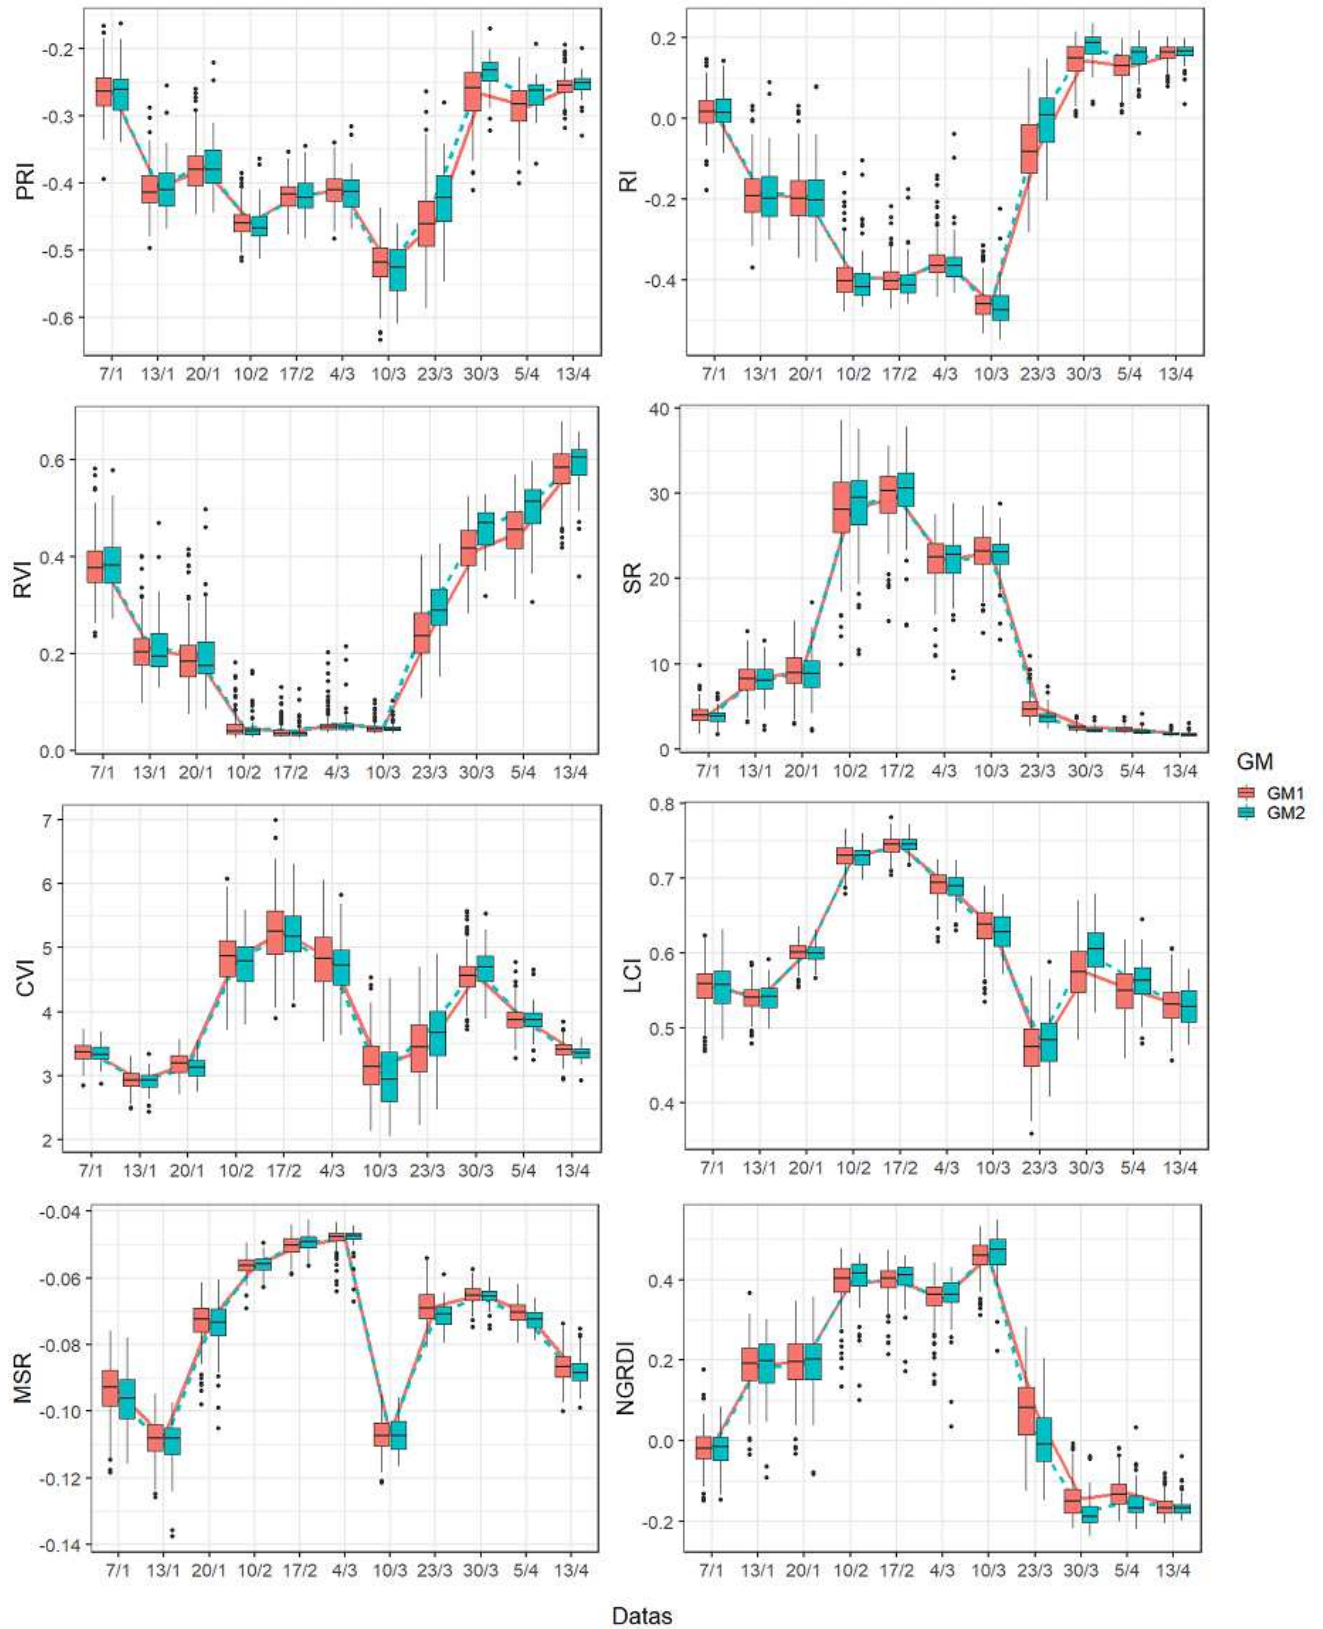


Figura 7. Avaliação gráfica temporal dos índices PRI, RI, RVI, SR, CVI, LCI, MSR E NGRDI no decorrer dos 11 dias de voo. Os pontos em vermelho representam a média do Grupo de maturação 1 (GM1) e em azul representam as médias do GM2, avaliados em cada data de voo para o experimento I.

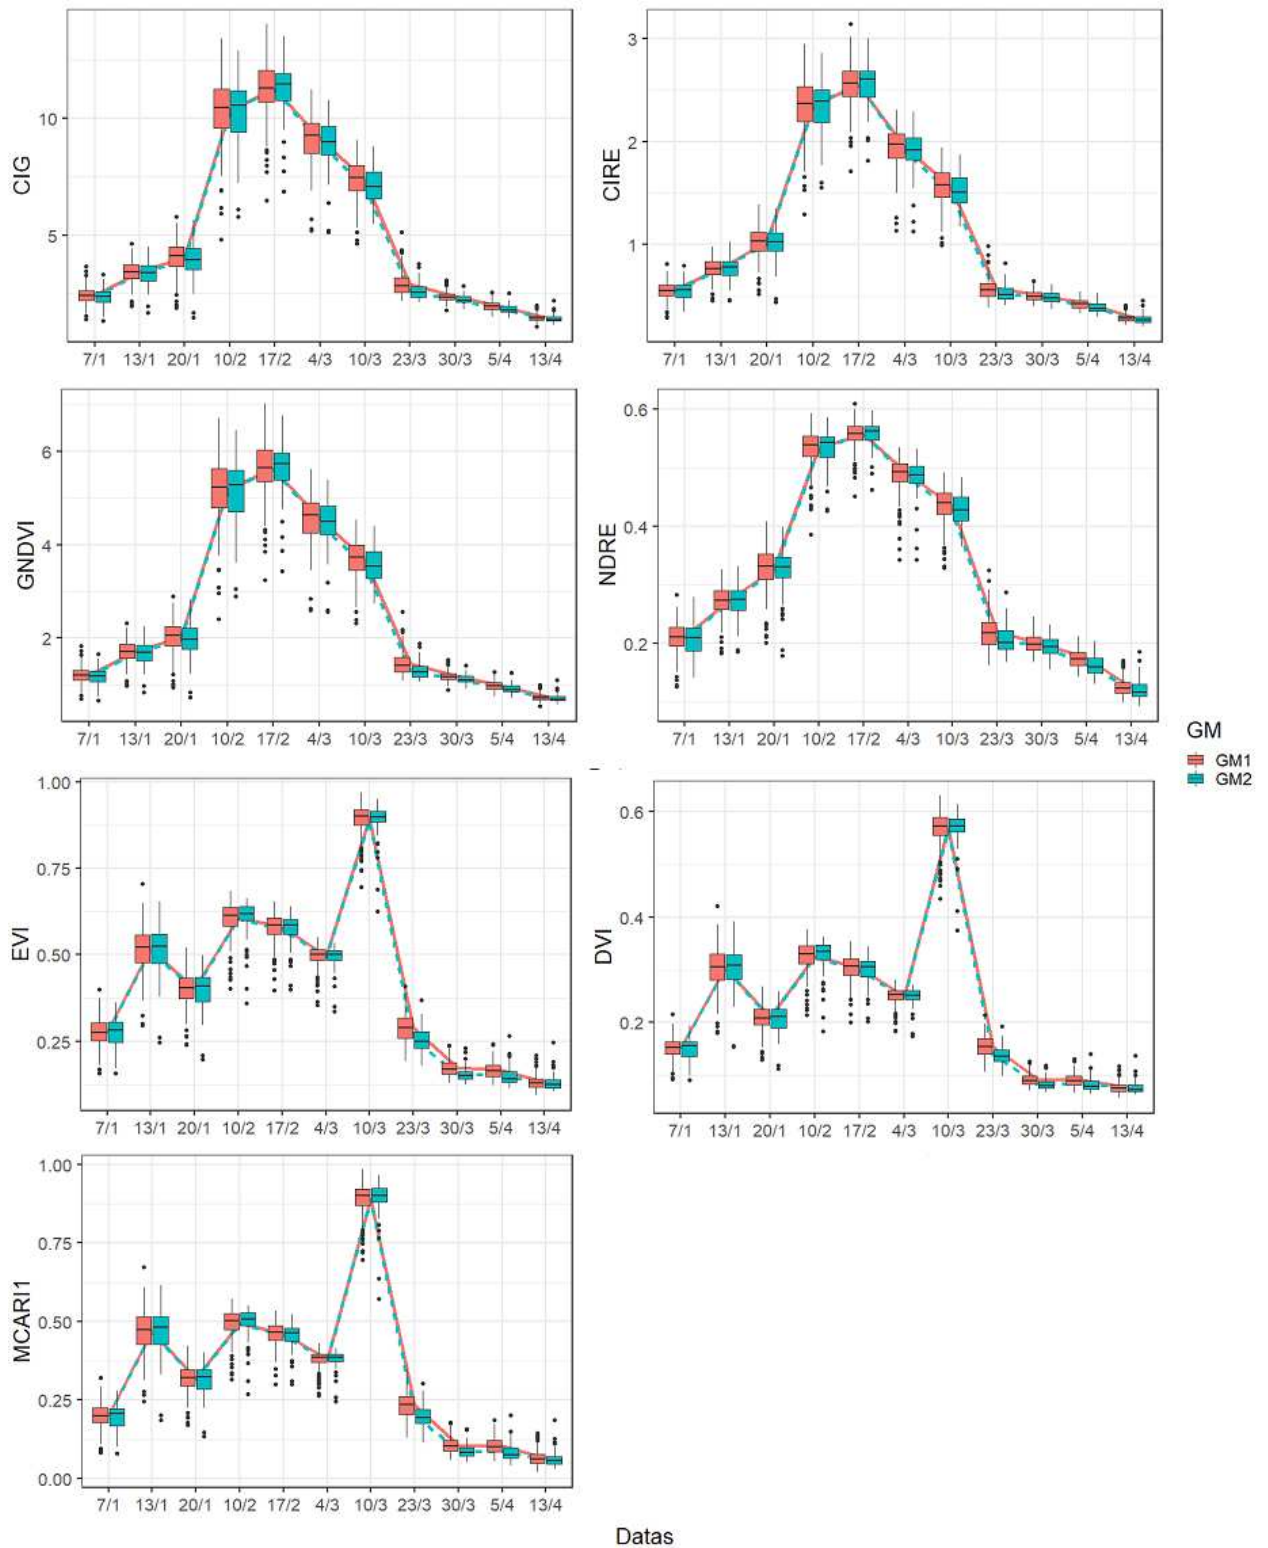


Figura 8. Avaliação gráfica temporal dos índices CIG, CIRE, GNDVI, NDRE, EVI, DVI e MCARI1 no decorrer dos 11 dias de voo. Os pontos em vermelho representam a média do Grupo de maturação 1 (GM1) e em azul representam as médias do GM2, avaliados em cada data de voo para o experimento I.

De acordo com as Figuras 7, 8 e 9 os índices que apresentaram maior diferença entre os grupos de maturação foram ARVI, NDVI, TVI, SIPI, PRI, RI, RVI, LCI e NGRDI. Para cada

índice citado, a diferença na distinção dos grupos de maturação é muito pequena, mas é mais aparente à medida que avançamos para o final do ciclo da cultura (data 23/03). Essa diferença seria esperada uma vez que a diferença entre a parcela mais precoce e a mais tardia foi de apenas 6 dias.

No dia 23/03 as plantas possuíam 113 dias de plantio, entre os estádios R6 e R7 (THOMAS, 2018). O estádio R6 é caracterizado por vagem de um dos 4 últimos nós do caule contendo grãos verdes cheios preenchendo suas cavidades, com folha completamente desenvolvida, enquanto no estádio R7 uma vagem normal no caule apresenta coloração madura (FEHR; CAVINESS, 1977). Uma possível explicação para a melhor diferenciação dos IVs nesses estádios é o início da degradação da clorofila no R7.

CONCLUSÃO

O modelo criado baseado nos IVs mencionados, utilizando Rede Neural Feed Forward, obteve precisão e acurácia acima de 60% na classificação de produtividade, 100 dias após o plantio, quando as plantas encontravam-se acima do estádio R5.

Os IVs não mostraram diferenças significativas para os dados de refletância do dossel coletados ao longo do ciclo, que pudessem contribuir para identificar cultivares mais precoces. No entanto, entre as datas 23/03 e 5/04, 113 dias após o plantio, dos estádios R6 a R7, os IVs ARVI, NDVI, TVI, SIPI, PRI, RI, RVI, LCI e NGRDI se mostraram mais aptos a identificar diferença entre os grupos de maturação.

O uso de imagens multiespectrais pode auxiliar os melhoristas reduzindo a coleta de dados em campo, no caso da maturidade, e colaborar na seleção de genótipos superiores em relação a produtividade.

REFERÊNCIAS BIBLIOGRÁFICAS

AINSWORTH, Elizabeth A. et al. Accelerating yield potential in soybean: potential targets for biotechnological improvement. **Plant, cell & environment**, v. 35, n. 1, p. 38-52, 2012.

ALABI, Tunrayo R. et al. Estimation of soybean grain yield from multispectral high-resolution UAV data with machine learning models in West Africa. **Remote Sensing Applications: Society and Environment**, p. 100782, 2022.

ALLIPRANDINI, Luis Fernando. Desafios no melhoramento de soja como cultura antecessora ao milho de segunda safra.

AMABILE, R. F.; VILELA, M. S.; PEIXOTO, J. R. Melhoramento de plantas: variabilidade genética, ferramentas e mercado. Embrapa Cerrados-Livro técnico (INFOTECA-E), 2018.

BARNES, E. M. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington, MN, USA**. 2000. p. 6.

BERNARD, R.L. 1971. Two major genes for time of flowering and maturity in soybeans. **Crop Science**, v.11, p.242–244.

BERNARDI, A. d. C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 596 p., 2014.

BIRTH, Gerald S.; MCVEY, George R. Measuring the color of growing turf with a reflectance spectrophotometer 1. **Agronomy Journal**, v. 60, n. 6, p. 640-643, 1968.

BLOSFELD, Letycia Hass. Correlação linear entre os índices de vegetação NDVI e NDRE com a produtividade do milho segunda safra. 2018. 35f. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrícola e Ambiental) – Universidade Federal de Mato Grosso, Instituto de Ciências Agrárias e Ambientais, Sinop, 2018.

BONATO, E.R.; VELLO, N.A. 1999. E6, a dominant gene conditioning early flowering and maturity in soybeans. **Genetics and Molecular Biology**, v.22, p.229–232.

BROGE, N. H.; LEBLANC, E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote Sensing of Environment**, v. 76, n. 6, p. 156- 172, 2001. [http://dx.doi.org/10.1016/S0034-4257\(00\)00197-8](http://dx.doi.org/10.1016/S0034-4257(00)00197-8)

BUZZELL, R.I. 1971. Inheritance of a soybean flowering response to fluorescent-daylength conditions. **Canadian Journal of Genetics and Cytology**, v.13, p.703–707.

BUZZELL, R.I.; VOLDENG, H.D. 1980. Inheritance of insensitivity to long daylength. **Soybean Genetics Newsletter**, v.7, p.26–29.

CÂMARA, A. R. et al. Avaliação de componentes de produção em soja de tipo de crescimento determinado e indeterminado de ciclo precoce recomendados para Região Central do Brasil. In: **Embrapa Soja-Resumo em anais de congresso (ALICE)**. In: REUNIÃO DE PESQUISA DE SOJA DA REGIÃO CENTRAL DO BRASIL, 32., 2011, São Pedro, SP. Resumos expandidos... Londrina: Embrapa Soja, 2011. p. 259-261. Editado por Adilson de Oliveira Junior, Odilon Ferreira Saraiva, Regina Maria Villas Bôas de Campos Leite., 2011.

CAMARGO, T. V.; MORAES, M. C. Sistema integrado de soja precoce e milho safrinha. DuPont Pioneer. 2014. Disponível em: <http://www.pioneersementes.com.br/media-center/artigos/170/sistema-integrado-de-soja-precoce-e-milho-safrinha> . Acesso em: 19 de julho de 2021.

- CHEN, Jing M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229-242, 1996.
- COBER, E.R.; MOLNAR, S.J.; CHARETTE, M.; VOLDENG, H.D. 2010. A new locus for early maturity in soybean. **Crop Science**, v.50, p.524– 527.
- COBER, E.R.; VOLDENG, H.D. 2001. A new soybean maturity and photoperiod-sensitivity locus linked to E1 and T. **Crop Science**, v.41, p.698–701.
- CONAB. Acompanhamento da safra brasileira: grãos - safra 2020/21 - décimo levantamento. Companhia Nacional de Abastecimento, v. 8, n. 10, p. 1-110, 2017. ISSN: 2318-6852.
- DALL'AGNOL, A. A soja no brasil: evolução, causas, impactos e perspectivas. In: **Embrapa Soja-Artigo em anais de congresso (ALICE)**. In: CONGRESO DE LA SOJA DEL MERCOSUR, 5.; FORO DE LA SOJA ASIA, 1., 2011, Rosário. Un grano: un universo. [Rosário: Asociación de la Cadena de la Soja Argentina], 2011. 4 p. 1 CD-ROM. MERCOSOJA 2011., 2011.
- DALL'AGNOL, Amélio et al. O complexo agroindustrial da soja brasileira. **Embrapa Soja-Circular Técnica (INFOTECA-E)**, 2007.
- DATT, Bisun. A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using Eucalyptus leaves. **Journal of Plant Physiology**, v. 154, n. 1, p. 30-36, 1999.
- DE ALMEIDA, Leones Alves et al. Melhoramento da soja para regiões de baixas latitudes. **Embrapa Meio-Norte-Capítulo em livro científico (ALICE)**, 1999.
- DUCLÓS, Nei. A marcha do grão de ouro. **Soja: a cultura que mudou o Brasil. Florianópolis: Expressão**, 2014.
- ESCADAFAL, Richard; HUETE, A. Etude des propriétés spectrales des sols arides appliquée à l'amélioration des indices de végétation obtenus par télédétection. **Comptes Rendus de l'Académie des Sciences. Série 2: Mécanique...**, v. 312, p. 1385-1391, 1991.
- FEHR, Walter R.; CAVINESS, Charles E. **Stages of soybean development**. Ames: Iowa State University of Science and Technology, 1977.
- FERREIRA, João et al. GRUPOS DE MATURAÇÃO DA CULTURA DA SOJA AVALIADOS POR IMAGENS AÉREAS OBTIDAS POR VANT. 2020. Dissertação (Mestrado Profissional em Bioenergia e Grãos) - Instituto Federal Goiano, Campus Rio-Verde. 30/10/2020.
- FINOTO, E. L.; CARREGA, W. C.; SEDIYAMA, T.; DE ALBUQUERQUE, J. A. A.; CECON, P. R.; REIS, M. S. Efeito da aplicação de fungicida sobre caracteres agrônômicos e severidade das doenças de final de ciclo na cultura da soja. **Revista Agro@mbiente On-line**, v. 5, n. 1, p. 44-49, 2011.
- FORMAGGIO, Antonio Roberto; SANCHES, Ieda Del'Arco. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017.
- FRANCHINI, J. C. et al. Uso de imagens aéreas obtidas com drones em sistemas de produção de soja. Embrapa Soja-Documents (INFOTECA-E), 2018.
- GAMON, J. A.; PENUELAS, Josep; FIELD, C. B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of environment**, v. 41, n. 1, p. 35-44, 1992.
- GAZZONI, D. L.; DALL'AGNOL, A. A saga da soja: de 1050 aC a 2050 dC. **Embrapa Soja-Livro científico (ALICE)**, 2018.
- GESTEIRA, G. de S.; ZAMBIAZZI, E. V.; BRUZI, A. T.; SOARES, I. O.; REZENDE, P. M. de; SILVA, K. B. Seleção fenotípica de cultivares de soja precoce para a região Sul de Minas Gerais. **Revista Agrogeoambiental**, Pouso Alegre, v. 7, n. 3, p. 79-88, set. 2015.

- GHORBANI, Ardavan et al. Estimating aboveground net primary production (ANPP) using Landsat 8-based indices: A case study from Hir-Neur rangelands, Iran. **Rangeland Ecology & Management**, v. 73, n. 5, p. 649-657, 2020.
- GIOVOS, Rigas et al. Remote sensing vegetation indices in viticulture: a critical review. **Agriculture**, v. 11, n. 5, p. 457, 2021.
- GITELSON, A. A.; VERMA, S. B.; VIÑA, A.; RUNDQUIST, D. C.; KEYDAN, G.; Leavitt, B. (2003). Novel technique for remote estimation of CO₂ flux in maize. **Geophysical Research Letters**, 30 (9), 1486.
- 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**, v. 58, n. 3, p. 289-298, 1996.
- HABOUDANE, Driss et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote sensing of environment**, v. 90, n. 3, p. 337-352, 2004.
- HAGHIGHATTALAB, Atena et al. Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries. **Plant Methods**, v. 12, n. 1, p. 1-15, 2016.
- HASTIE, T. TIBSHIRANI, R., FRIEDMAN, J. The elements of statistical learning. Second Edition New York. Springer, 2009. 745p.
- HATFIELD, Jerry L. et al. Applications of vegetative indices from remote sensing to agriculture: Past and future. **Inventions**, v. 4, n. 4, p. 71, 2019.
- HIRAKURI, Marcelo Hiroshi; LAZZAROTTO, Joelsio José. O agronegócio da soja nos contextos mundial e brasileiro. 2014.
- HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote sensing of environment**, v. 59, n. 3, p. 440-451, 1997.
- JORDAN, Carl F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663-666, 1969.
- KAUFMAN, Yoram J.; TANRE, Didier. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.
- KHATREE, R.; NAIK, D.N. Multivariate data reduction and discrimination with SAS software. New York: John Wiley and Sons, 2000. 584p.
- KIIHL, RAS; GARCIA, A. The use of the long-juvenile character in breeding cultivares de soja. In: **4 Conferência Mundial de Pesquisa de Soja**. Buenos Aires: AASoja, 1989.
- KONG, F. et al. A new dominant gene conditions early flowering and maturity in soybean. **Crop Science**, v. 54, n. 6, p. 2529-2535, 2014.
- KOPIER, Alberto A. et al. Redes Neurais Artificiais e suas aplicações no setor elétrico. **Revista de Engenharias da Faculdade Salesiana**, v. 1, n. 9, p. 27-33, 2019.
- KURBANOV, Rashid K.; ZAKHAROVA, Natalya I. Application of vegetation indexes to assess the condition of crops. **Agricultural machinery and technologies**, v. 14, n. 4, p. 4-11, 2020.
- KUREEL, Neha et al. Modelagem da saúde e estresse da vegetação usando dados de sensoriamento remoto hiperespectral. **Modelagem de Sistemas Terrestres e Meio Ambiente**, v. 8, n. 1, pág. 733-748, 2022.
- LAUDANI, Antonino et al. On training efficiency and computational costs of a feed forward neural network: a review. **Computational intelligence and neuroscience**, v. 2015, 2015.

- LUIZ, Marlize Cristina Pinheiro et al. Efeito da época de semeadura e população de plantas sobre o potencial produtivo e caracteres agronômicos em soja. 2018.
- MASUKA, Benhilda et al. Gains in maize genetic improvement in Eastern and Southern Africa: I. CIMMYT hybrid breeding pipeline. **Crop Science**, v. 57, n. 1, p. 168-179, 2017.
- MCBLAIN, B.A.; BERNARD, R.L. 1987. A new gene affecting the time of flowering and maturity in soybeans. **The Journal of Heredity**, v.78, p.160–162.
- NEPOMUCENO, A. L.; FARIAS, J. R. B.; NEUMAIER, N. **Características da soja**. Embrapa-CNPSo, 2008. Disponível em: <https://www.embrapa.br/en/agencia-de-informacao-tecnologica/cultivos/soja/pre-producao/caracteristicas-da-especie-e-relacoes-com-o-ambiente/caracteristicas-da-soja>. Acesso em: 08/08/2022.
- NETO, AAO. A produtividade da soja: análise e perspectivas. 2017.
- NOVO, E. M. L. M. 2010. Sensoriamento Remoto: Princípios e Aplicações.4 ed. Editora Edgard Blucher Ltda. São Paulo.
- OLIVEIRA, Vinícius Henrique Dias de et al. Unidades de Gestão Diferenciada por meio de índices de vegetação e mapas de produtividade. 2021.
- Penuelas, J.; Baret, F.; Filella, I. Semi-empirical indices to assess arotenoids/chlorophyll a ration from leaf spectral reflectance. **Photosynthetica**, v. 31, p. 221-230, 1995.
- POLIZEL, Anely Castilho. Adaptability and stability of soybean genotypes in the state of Mato Grosso, Brazil, and reaction of 111 genotypes to the Asian rust. 2007. 186 f. Tese (Doutorado em Ciências Biológicas) - Universidade Federal de Uberlândia, Uberlândia, 2007.
- RANJAN, Rakesh et al. Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology. **Information Processing in Agriculture**, v. 6, n. 4, p. 502-514, 2019.
- RAY, J.D.; HINSON, K.; MANKONO, J.E.B.; MALO, M.F. 1995. Genetic control of a long-juvenile trait in soybean. **Crop Science**, v.35, p.1001– 1006.
- REZNICK, João PK; PAULETTI, Volnei; BARTH, Gabriel. Estimativa de campo com NDVI da produtividade de grãos e qualidade da farinha de trigo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, p. 801-806, 2021.
- RIBEIRO, Larissa Pereira. Índices de vegetação no melhoramento da soja: aplicações na escolha de genitores e na predição do ciclo. 2019. 52 f. Tese (Doutorado em Genética e Melhoramento) - Universidade Federal de Viçosa, Viçosa. 2019
- RICHARDSON, Arthur J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric engineering and remote sensing**, v. 43, n. 12, p. 1541-1552, 1977.
- ROUJEAN, Jean-Louis; BREON, Francois-Marie. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote sensing of Environment**, v. 51, n. 3, p. 375-384, 1995.
- SAMANFAR, B. et al. Mapping and identification of a potential candidate gene for a novel maturity locus, E10, in soybean. **Theoretical and Applied Genetics**, v. 130, n. 2, p.377-390, 2017.
- SANDRINI, Fernando de Oliveira Turci et al. Índices de vegetação na estimativa da produtividade do feijoeiro cultivado sob doses de nitrogênio. **Revista Brasileira de Ciências Agrárias**, v. 14, n. 4, p. 1-8, 2019.
- SCHULZ, Adriano Dietterle et al. Fenômica: Interrelações dos atributos edafoclimáticos com a produtividade da soja. **Salão do Conhecimento**, v. 7, n. 7, 2021.
- SEDIYAMA, T. Tecnologia de produção e usos da soja. Londrina: Mecenias, 2009. 314 p.

- SEDIYAMA, Tuneo; SILVA, Felipe; BORÉM, Aluizio. Soja: do plantio à colheita. UFV, 2015.
- SEIXAS, C. D. S. et al. Tecnologias de produção de soja. **Embrapa Soja-Sistema de Produção (INFOTECA-E)**, 2020.
- SILVA, Felipe et al. **Soja: do plantio à colheita**. Oficina de Textos, 2022.
- SILVA, Felipe et al. **Melhoramento da Soja**. Editora UFV, 2017.
- SOKOLOVA, Marina; JAPKOWICZ, Nathalie; SZPAKOWICZ, Stan. Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation. In: **Australasian joint conference on artificial intelligence**. Springer, Berlin, Heidelberg, 2006. p. 1015-1021.
- SOUZA, Mirayr Raul Quadros de. Estimativa de biomassa de trigo usando imagens de alta resolução espacial a partir de veículo aéreo não tripulado. 2018.
- TA, Na; CHANG, Qingrui; ZHANG, Youming. Estimation of Apple Tree Leaf Chlorophyll Content Based on Machine Learning Methods. **Remote Sensing**, v. 13, n. 19, p. 3902, 2021.
- TAYADE, Rupesh et al. Utilization of Spectral Indices for High-Throughput Phenotyping. **Plants**, v. 11, n. 13, p. 1712, 2022.
- TEIXEIRA, Fernanda Gabriela. Herança da precocidade e de caracteres agrônômicos em soja e seleção de linhagens com base em índices de seleção. 2017. 88 f. Dissertação (Mestrado em Agronomia) - Universidade Federal de Uberlândia, Uberlândia, 2017. DOI <http://doi.org/10.14393/ufu.di.2017.563>
- THOMAS, Andre Luis. Soja: tipos de crescimento da planta. 2018.
- TRINDADE, Filipe Silveira et al. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. **Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences**, v. 62, 2019.
- VAN KLOMPENBURG, Thomas; KASSAHUN, Ayalew; CATAL, Cagatay. Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture**, v. 177, p. 105709, 2020.
- VERNETTI, F.J. Soja: Genética e Melhoramento. Campinas: Fundação Cargil, v.2, 1983.
- VINCINI, M. et al. Comparison of narrow-band and broad-band vegetation indices for canopy chlorophyll density estimation in sugar beet. In: **Precision agriculture'07. Papers presented at the 6th European Conference on Precision Agriculture, Skiathos, Greece, 3-6 June, 2007**. Wageningen Academic Publishers, 2007. p. 189-196.
- WANG, Feifei et al. A new dominant locus, E11, controls early flowering time and maturity in soybean. **Molecular Breeding**, v. 39, n. 5, p. 1-13, 2019.
- WATANABE, S.; HARADA, K.; ABE, J. Genetic and molecular bases of photoperiod responses of flowering in soybean. **Breeding science**, v. 61, n. 5, p. 531-543, 2012.
- XUE, Jinru; SU, Baofeng. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of sensors**, v. 2017, 2017.
- YOOSEFZADEH-NAJAFABADI, Mohsen et al. Application of machine learning algorithms in plant breeding: predicting yield from hyperspectral reflectance in soybean. **Frontiers in plant science**, v. 11, p. 624273, 2021.
- ZHANG, Ke et al. Predicting rice grain yield based on dynamic changes in vegetation indexes during early to mid-growth stages. **Remote sensing**, v. 11, n. 4, p. 387, 2019.
- ZHOU, Jing et al. Estimation of the maturity date of soybean breeding lines using UAV-based multispectral imagery. **Remote Sensing**, v. 11, n. 18, p. 2075, 2019.