

Comportamento espectral da soja e predição de produtividade com uso do NDVI



<https://doi.org/10.56238/tecnolocienagrariabiosoci-009>

William Peducze Possebon

Engenheiro Agrônomo
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Gustavo Kruger Gonçalves

Professor Adjunto
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Lenize Dornelles Gomes

Engenheira Agrônoma
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Guilherme Bueno Borges

Engenheiro Agrônomo
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Gerciane Correa Duarte

Engenheira Agrônoma
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Bibiana Costa Machado

Engenheira Agrônoma
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Emilio Mateus Schüller

Engenheiro Agrônomo
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Ruben Fernando de Lara

Engenheiro Agrônomo
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Paulo Elias Borges Rodrigues

Engenheiro Agrônomo
Universidade Estadual do Rio Grande do Sul, Santana do Livramento-RS

Cassiano Jivago Lemos da Silva

Mestre em Ciência do Solo
Universidade Federal de Santa Maria, Santa Maria-RS

RESUMO

O uso de imagens de sensoriamento remoto possibilita a estimativa da produtividade da cultura da soja através de índices de vegetação, sendo um dos mais utilizados o NDVI. O objetivo foi determinar o comportamento do NDVI durante o ciclo de desenvolvimento da soja, sua correlação com a produtividade e estimar através de regressões lineares a produtividade de grãos. Os dados foram obtidos em Dom Pedrito-RS da safra agrícola 2021/2022, em área de 18,44 ha. Foram selecionadas dezesseis imagens durante o ciclo de cultivo da soja de satélites da constelação Planet com cálculos de NDVI para cada imagem, além da extração de dados de produtividade de grãos de monitor Gen4 Command Center 4600 da John Deere. Uma malha amostral de 262 polígonos com área de 900 m² cada foi utilizada para extração da produtividade e NDVI utilizando o software QGIS Białowieża, versão 3.22.14 e exportados em formato .XLS para análise em planilhas. Os dados de produtividade foram agrupados em 5 (cinco) classes de acordo com a porcentagem em relação a produtividade média: < 85% da média; 85 a 95% da média; 95 a 105% da média, 105 a 115% da média e > 115% da média. Metade dos dados amostrais (131 polígonos) foram utilizados para análise de correlação e regressões lineares simples quando as correlações fossem fortes e significativas e a outra metade para validação dos modelos gerados. A validação dos modelos foi realizada pela raiz quadrada do erro quadrado médio (RMSE) e a raiz quadrada do erro quadrado médio normalizado (nRMSE) e o coeficiente de determinação (R²). Os resultados demonstraram que o NDVI possui comportamento exponencial da semeadura a colheita da soja com maior valores encontrados próximos aos 92 DAS (dias após semeadura). NDVI dos 68 aos 80 DAS e dos 120 a 126 DAS produziram correlação na média de 0,96 com a produtividade da soja. Os modelos gerados aos 80, 120 e 126 DAS permitiram estimar a produtividade de soja via NDVI com erro médio de ± 167,51 kg ha⁻¹ sendo que o NDVI pode prever com antecedência de 70 dias da colheita e precisão de ± 246,17 kg ha⁻¹ a produtividade em soja para o talhão estudado. Conclui-se que o NDVI pode ser utilizado para estimar a produtividade da soja.

Palavras-chave: Agricultura de precisão, Índice de vegetação, *Glycine max*.



1 INTRODUÇÃO

O Brasil é o maior produtor mundial de soja, seguido pelos Estados Unidos (PRADEBON et al., 2023). Dados da safra 2022/2023, demonstram uma produtividade estimada de 151.4 milhões de toneladas de grãos, em uma área aproximada de 43,52 milhões de hectares (CONAB, 2023), sendo que nos últimos 12 anos, a área de produção da oleaginosa no país aumentou 42.5 % e 56.2 % no volume total produzido.

A cultura é importante na cadeia produtiva pelas formas de uso, incluindo ração animal, óleo, farelo e biodiesel (RODRIGUES et al, 2023) e fonte de renda para setores agroindustriais, como insumos e máquinas (COSTA; SANTANA, 2013).

Devido sua importância na economia nacional é buscado o aumento da sua produção. Entretanto, os talhões não são homogêneos e a produtividade final é reduzida devido a fatores do ambiente, solo e planta. Desta forma, para entender o motivo dos baixos rendimentos é necessário possuir meios que demonstrem o porquê está baixa produtividade ocorre e um dos principais levantamentos métodos é o mapa de produtividade por talhão.

Nas últimas décadas o emprego de tecnologia no campo transformou a agricultura empresarial através de processos como a modernização de maquinários, direcionamento no uso de insumos, semeadura sem revolvimento do solo, modificação da genética de plantas e uso da agricultura de precisão (SANTI et al., 2013). O avanço da agricultura convencional para agricultura digital mostra que os diferentes campos de produção não devem ser tratados de maneira homogênea em relação à medição de variáveis.

A geolocalização de zonas permitiu captar e mensurar a variabilidade espacial dos atributos agrícolas, considerando de forma heterogênea o ambiente produtivo, buscando aumentar a eficiência, com base no manejo diferenciado de talhões na agricultura (TSCHIEDEL, ; FERREIRA, 2002).

Como uma das ferramentas de AP a medição de produtividade das culturas varia espacialmente e assim podem ser estudadas através de técnicas geoestatísticas que permitem elaborar mapas e delimitar áreas de manejo diferenciadas (FARIAS, 2003). A geração de mapas de produtividade é uma prática bastante comum em países mais desenvolvidos, onde o monitoramento da produtividade é considerado o primeiro passo na implantação da AP (GIMENEZ; MOLIN, 2004).

A etapa de construção de mapas de produtividade é realizada com alta densidade espacial de dados para a construção de mapas que caracterizem detalhes da lavoura (MARTELLO et al., 2022). A medição da produtividade é realizada por sensores instalados em colhedoras, que mensuram a quantidade de produto colhida e com auxílio de receptor GPS fornece o posicionamento georreferenciando da produção, possibilitando seu mapeamento (MENEGATTI; MOLIN, 2004), esta geração de dados de produtividade possuem acurácia entre 2 a 3% na totalização dos grãos colhidos, segundo fabricantes (GIMNESZ; MOLIN, 2004).



Os mapas de produtividade para caracterizar a variabilidade das lavouras permite representar graficamente o resultado dos manejos empregados (SANTI et al, 2013), bem como limitações inerentes do terreno como restrições hídricas, compactação, plantas daninhas, textura do solo. Desta forma a geração de mapas de produtividade são utilizados na investigação das causas da variabilidade, e podem ser um recurso eficaz nas decisões sobre o melhor manejo do solo e planta (AMADO et al, 2007).

Apesar de ser um recurso bastante difundido, o uso de sensores de colheita em máquinas ainda é oneroso para muitos agricultores sendo necessário utilizar de novas alternativas visando a previsão do rendimento de grãos e possíveis zonas de anomalia na lavoura.

A produtividade da cultura pode ser estimada a partir de sua relação com o vigor da cultura, que por sua vez, pode ser determinado via sensoriamento remoto, pela sua relação com determinados índices de vegetação gerados a partir de imagens multiespectrais. A obtenção das estimativas de produtividade permite antever se a atividade terá lucros ou prejuízos.

Neste contexto, o uso sensoriamento remoto usando índices de vegetação podem ser aliados a prever com antecedência a produtividade esperada de cada talhão, podendo ser utilizada no planejamento antecipado da propriedade com relação a custos, aquisição de insumos, maquinários, logística de transporte e comercialização de produto.

Atualmente, se dispõe de imagens com alta resolução temporal para confecção de índices de vegetação para se utilizar no estudo das características espectrais e temporais da cultura da soja durante seu ciclo fenológico, sendo um dos mais difundidos o índice de vegetação por diferença normalizada (NDVI) (ROUSE et al., 1974), que é amplamente utilizado na estimativa de biomassa e pode contribuir na estimativa de produtividade, visto que maior biomassa tende ao maior vigor de plantas e conseqüente maior produção de grãos.

Assim, o objetivo deste trabalho foi avaliar o comportamento do NDVI durante uma safra agrícola, sua correlação com a produtividade da soja e ajuste de modelos de regressão linear para prever a produtividade de grãos de soja com base no NDVI em uma Fazenda no município de Dom Pedrito-RS, Brasil.

2 MATERIAL E MÉTODOS

O trabalho foi realizado com dados coletados entre novembro de 2021 e abril de 2022, em área agrícola comercial de 18,44 hectares, cultivada com soja no município de Dom Pedrito, RS, na latitude $-31^{\circ}10'28''$ S, e longitude $-54^{\circ}62'66''$ W, e altitude média de 152 m. A cultivar utilizada foi a Dom Mario 5958 semeada em semeadura direta em espaçamento de 0.45 m entre linhas na data de 15 de novembro de 2021. O solo da área experimental possuía cobertura vegetal de azevém o qual foi manejado com herbicidas anterior a semeadura.



A colheita foi realizada em 14 de abril de 2022, com colhedora modelo S760 da marca John Deere, com potência de 320 cv, equipada com plataforma de 9,14 metros e capacidade de armazenamento no graneleiro de 10.600 litros. A colhedora era equipada com monitor de colheita Gen4 Command Center 4600 do qual se obteve os mapas de produtividade da colhedora em arquivos formato vetorial georreferenciado (*shapefile*) e umidade corrigida para 13% através da plataforma digital da John Deere para computador PC (*Personal Computer*).

As análises geoespaciais dos dados de colheita e índice de vegetação foram analisados e processados com auxílio do software QGIS Białowieża, versão 3.22.14. Os mapas de colheita em formato vetorial foram rasterizados para permitir a extração dos valores de produção de cada ponto de amostragem, usando a ferramenta de rasterização do software QGIS.

As imagens de satélite para confecção do Índice de Vegetação por Diferença Normalizada (NDVI – *Normalized Difference Vegetation Index*) foram adquiridas da constelação de nanosatélites da Planet. As imagens Planet possuem resolução espacial de 3 metros e resolução radiométrica de 16 bits. As bandas são capturadas pelo instrumento óptico Planet Scope 0, Planet Scope 1 e Planet Scope 2, com configuração espectral de 4 bandas, sendo elas: (comprimento de onda médio) azul (ρ_{485}), verde (ρ_{545}), vermelho (ρ_{630}) e infravermelho próximo (ρ_{820}) (PLANET, 2022). As imagens adquiridas corresponderam ao período da semeadura a colheita sem interferência de nuvens sendo selecionadas 16 imagens durante o ciclo da soja.

O cálculo do NDVI foi realizado com o plugin “*Vegetation Index (Slope Based)*” utilizando das bandas infravermelho próximo e vermelho das imagens de satélite através da equação:

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$$

Em que:

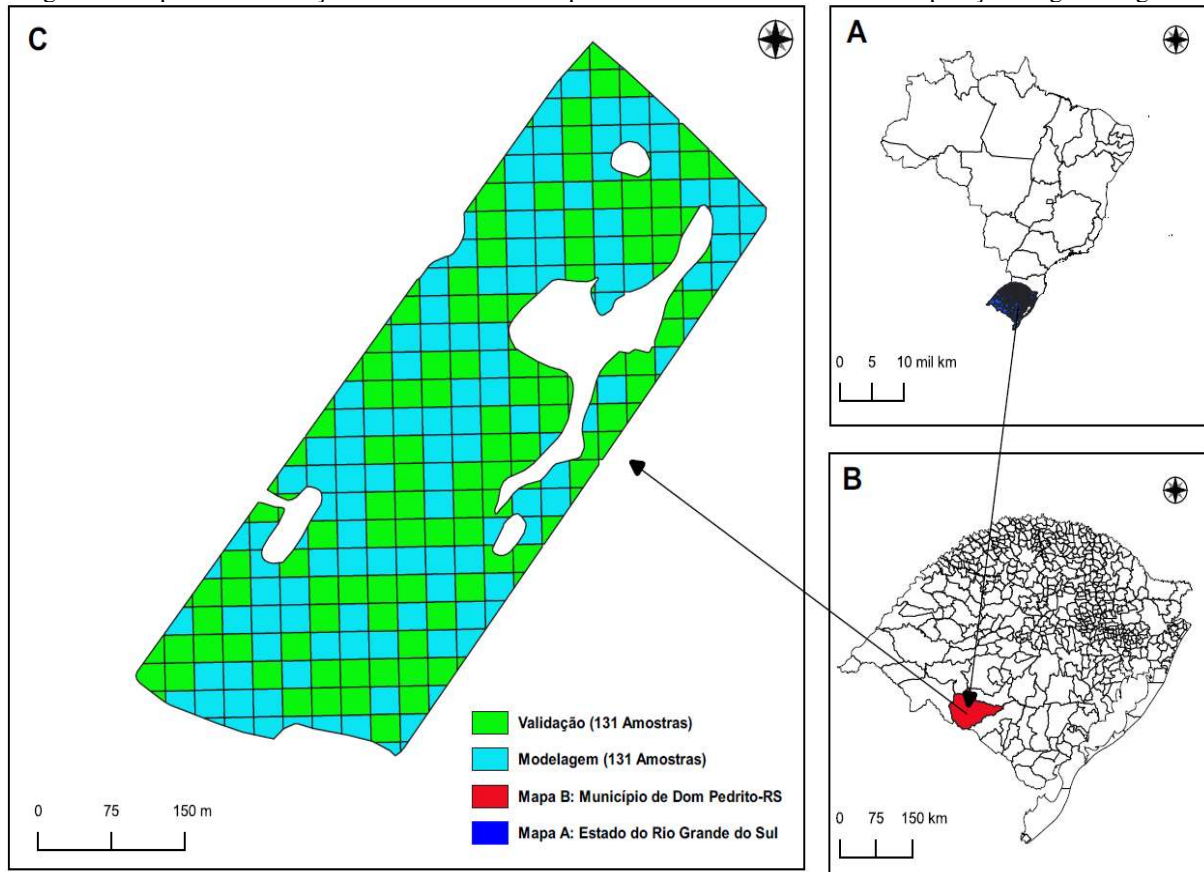
- NIR: Reflectância na Banda do Infravermelho Próximo
- RED: Reflectância na Banda do Vermelho

Para geração de modelo de predição da produtividade, foram capturados os dados de produtividade e NDVI para área de estudo. Foram utilizadas para modelagem as imagens que propuseram maiores NDVI médios, compreendidas entre Janeiro a Março de 2022.

A coleta de dados foi realizada com a plotagem de uma malha regular de 30 x 30 metros em forma de polígono (Figura 1C), totalizando 262 amostras, sendo capturados os valores da produtividade e NDVI para cada polígono através do plugin “*Add raster values to points*” do software Qgis, para cada uma das datas de imageamento.



Figura 1. Mapa de Localização da área de estudo e pontos de coletas de dados em disposição de grade regular.



Para modelagem e validação do modelo separou-se o conjunto de polígonos aleatoriamente com a ferramenta “*Seleção Aleatória*” do software QGIS com limiar de 50% dos polígonos para cada classe (131 amostras). As amostras, modelagem e validação, foram exportadas para planilha em formato .XLS para realização do ajustes de dados.

Na planilha .XLS a produtividade foi separada em 5 (cinco) classes (Figura 2) para realização da modelagem, sendo separadas a partir da média geral produtividades: < 85% da média; 85 a 95% da média; 95 a 105% da média, 105 a 115% da média e > 115% da média. Assim, o NDVI médio de cada classe de produtividade foi mensurado conjuntamente a separação da produtividade. Logo, cada data de imageamento ficou com 5 classes de produtividade e o NDVI médio de cada classe.

A análise do comportamento médio do NDVI durante o período de cultivo foi realizada através de gráfico de linhas e análise visual de mapas de NDVI. Os dados de produtividade e NDVI foram submetidas a análise de correlação de Pearson para cada data de imageamento avaliadas estatisticamente através do Teste “*T Student*” a 5% de probabilidade de erro.

As amostras/datas com correlações de Pearson positivas e significativas foram submetidas a análise de regressão entre os dados de produção de grãos (variável dependente) e os dados espectrais (variáveis independente) visando obter as equações lineares para estimativa da produtividade pelo



NDVI da cultura da soja no talhão de estudo, sendo os coeficientes de determinação analisados estatisticamente através do teste “F” a 5% de probabilidade de erro.

Os modelos de regressão que obtiveram coeficientes de determinação significativos foram validados usando o conjunto de valores extraídos para a validação do modelo. Os índices estatísticos analisados na validação foram o coeficiente de determinação (R^2), raiz quadrada média do erro (RMSE) em kg ha^{-1} e raiz quadrada média do erro normalizada (nRMSE) em percentual.

O cálculo da raiz quadrada média do erro (*Root Mean Square Error* (RMSE), foi realizado pela equação a seguir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y1 - Y2)^2}{n}}$$

Onde:

- n é o número de observações;
- Y1 são os valores de produtividade reais;
- Y2 são os valores de grãos estimados.

Todos os procedimentos estatísticos foram realizados com uso do software livre BioEstat (AYRES et al., 2007), assim como confecção de gráficos e tabelas foram realizados no software Microsoft Excel.

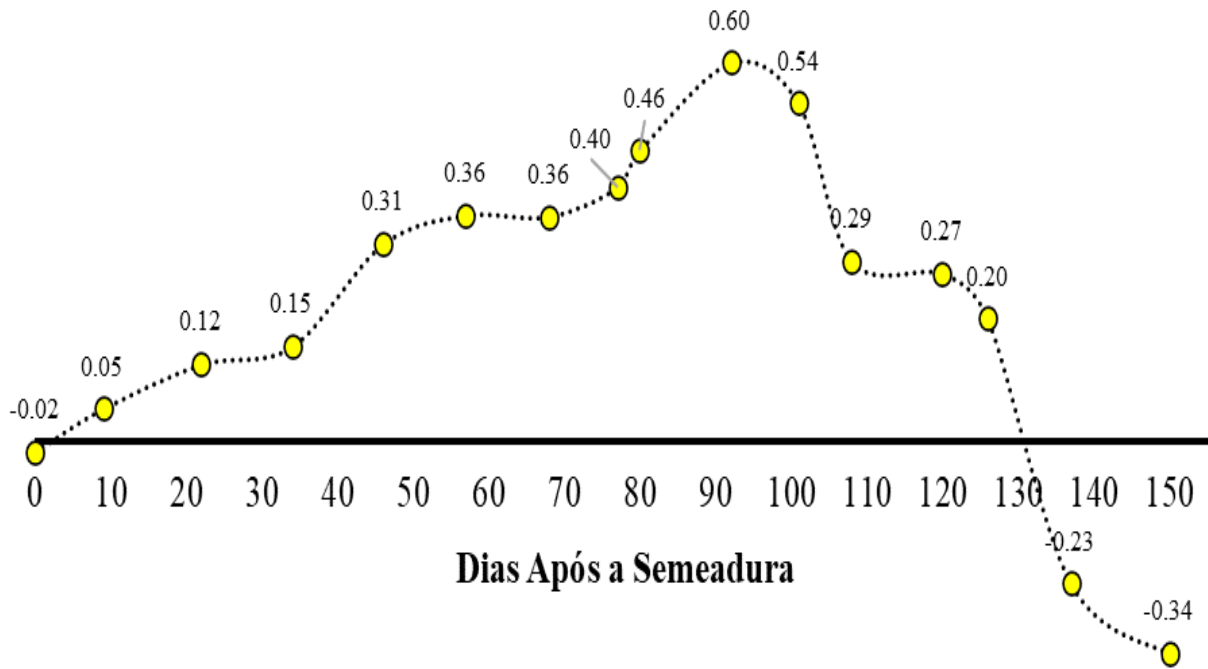
3 RESULTADOS E DISCUSSÃO

De acordo com a Figura 2 o NDVI médio mensal obteve comportamento exponencial durante o ciclo de desenvolvimento da cultura da soja, com variação entre -0,34 e 0,60. Os menores valores de NDVI foram encontrados no período de emergência (0 DAS) e senescência (137 DAS) nos meses de novembro e abril, respectivamente. Maiores valores de NDVI entre fechamento do dossel (80 DAS) e anterior a maturação fisiológica (101 DAS), de janeiro a fevereiro.

Os resultados corroboram com Alvino et al. (2020) em que valores elevados de NDVI correspondem a maior a densidade da cobertura vegetal, enquanto valores baixos são referentes a resposta do solo exposto e plantas secas.



Figura 2. Comportamento Médio do Índice de Vegetação por Diferença Normalizada durante o ciclo de desenvolvimento da cultura da soja.



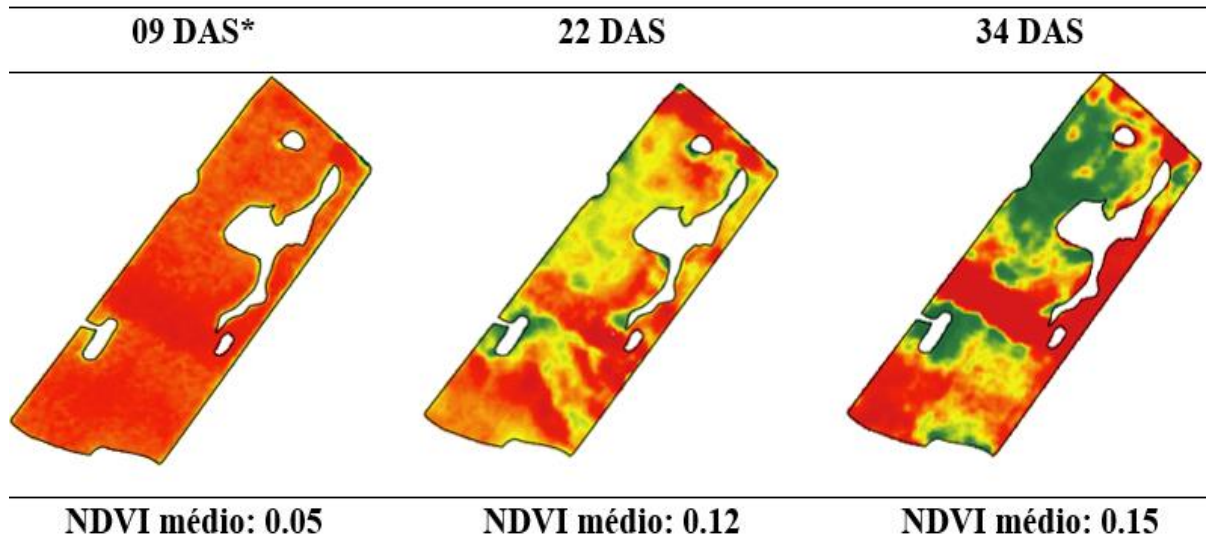
Allen; Pereira (2009) citaram que o NDVI aumenta com o desenvolvimento em área foliar e peso da biomassa seca de parte aérea das plantas. Em seu estudo Rodrigues et al. (2013) utilizando de imagens do satélite Landsat 5, verificaram que com aumento da biomassa, houve incremento do NDVI, sendo que o pico se deu no máximo vigor vegetativo da cultura.

A análise visual do NDVI durante o ciclo de imageamento demonstra que o período inicial de cultivo (Figura 3) obteve valor médio de 0,05 aos 09 dias após semeadura (DAS). Este valor está vinculado a baixa presença de cobertura vegetal fotossinteticamente ativa, visto que a cultura se encontrava em emergência com baixa reflectância na faixa do infravermelho próximo.

O valor do NDVI médio é positivo aos 09 DAS pois o manejo herbicida propiciou a cobertura de palha, não permitindo contribuição do solo exposto no índice, ao passo que seria negativo seu valor. Este cenário é interessante pois propiciou uma cobertura morta ao talhão estudado, e segundo Santos et al. (2018) a cobertura do solo com palha funciona como isolante a variação térmica do solo, evitando evaporação da água e reduzindo o impacto de gotas de chuva que poderiam levar a perda de solo.



Figura 3. Comportamento do NDVI durante o início do ciclo da cultura da soja.



DAS* = Dias após a Semeadura

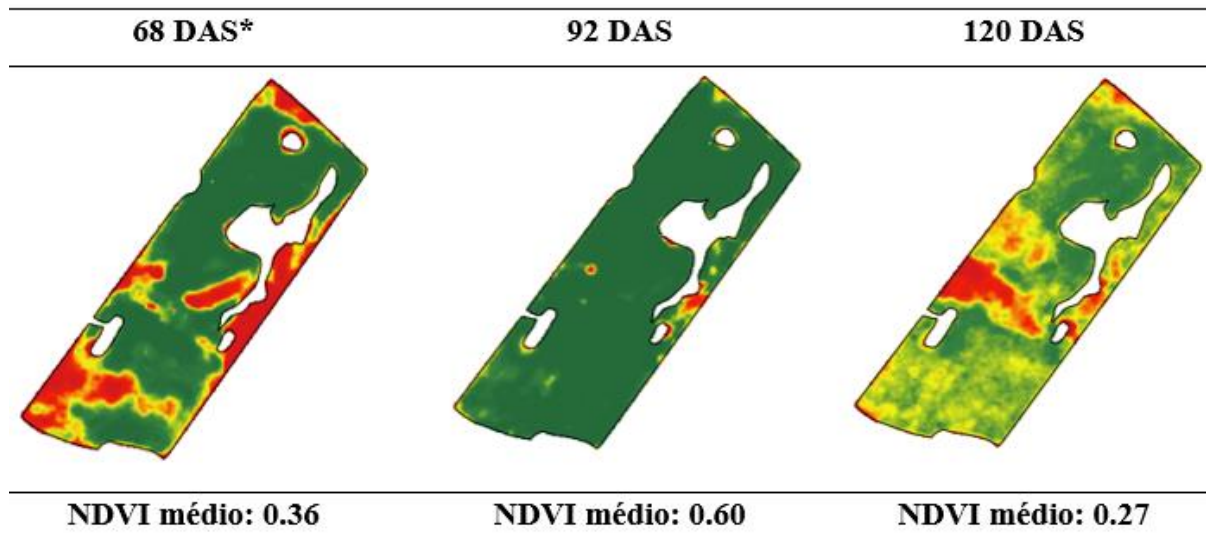
Conforme ocorreu o estabelecimento da cultura da soja aos 22 e 34 DAS os valores de NDVI aumentaram devido a maior contribuição da biomassa de parte aérea da soja emergida em relação ao solo e palha no índice, reduzindo a emissão de reflectância na faixa da banda vermelha e incrementando a faixa infravermelha.

A análise visual do comportamento do NDVI durante a fase intermediária de desenvolvimento da soja pode ser observada na Figura 4. Observa-se aos 92 DAS a menor discrepância visual do NDVI. Observado pelo coloração em verde escuro na imagem, NDVI mais próximos de 1 e valores de NDVI mais em vermelho valores mais próximos -1.

Este comportamento segundo Peng et al. (2017) está relacionado ao acúmulo de clorofila no tecido vegetal, onde maiores teores de clorofila levam a uma maior reflectância do dossel na faixa do infravermelho próximo e assim observaram que índices de vegetação como o NDVI, apresentam maiores valores durante o estágio reprodutivo da cultura onde há maior acúmulo do pigmento na folha.



Figura 4. Comportamento do NDVI durante a metade do ciclo da cultura da soja.



DAS* = Dias após a Semeadura

A alta sensibilidade do NDVI com condições de alta biomassa, encontrado no estudo, está em conformidade com Silva et al. (2015) os quais avaliaram o perfil temporal do NDVI na cultura da soja nas principais fases do ciclo de crescimento e encontraram os maiores valores de NDVI entre os estádios V4 (quatro folhas completas) e R4 (florescimento pleno). Os dados do trabalho demonstram condições semelhantes visto que dos 68 aos 120 DAS o coeficiente de variação foi de 29.64%, ou seja, indicando este período o de estabilidade e maior contribuição do índice.


Ainda, as imagens do NDVI aos 68 DAS e 120 DAS permite verificar zonas de menor valor do índice (tons avermelhados), sendo está uma ferramenta de gerenciamento de áreas. Assim, safras posteriores permite verificar se existe algum fator de impedimento local e corrigir.

Santi et al. (2013) citaram que o monitoramento via sensoriamento remoto da cultura da soja auxilia no diagnóstico dos aspectos que afetam o desenvolvimento da cultura e permite o manejo localizado de insumos. O NDVI está relacionado a fisiologia da planta, índice de área foliar, produção de biomassa e disponibilidade de água no solo (LE PAGE; ZRIBI, 2019) e portanto é um bom indicativo para se efetuar zonas de manejo no talhão.

Após 125 dias da sementeira (Figura 5), houve uma queda significativa no NDVI, ou seja, a vegetação perdeu seu vigor, indicando que a lavoura iniciou seu processo de maturação e consequente senescência.



Figura 5. Comportamento do NDVI durante o final do ciclo da cultura da soja.



DAS* = Dias após a Semeadura

Os valores encontrados estão de acordo com a constatação de Risso et al. (2012), que observaram baixos NDVIs durante a senescência da soja. Essa queda de NDVI na fase final do ciclo de desenvolvimento segundo Moreira et al. (2004) também é reflexo da influência do solo na refletância, reduzindo a influência da banda infravermelho próximo com maior resposta da banda vermelha, no cálculo do NDVI.

Kuiawski et al. (2017) citaram que a soja acumula a maior taxa de fotoassimilados nos estádios intermediários de desenvolvimento com maiores valores de NDVI. Por outro lado, ao final do ciclo, os valores tendem a reduzir, pois a cultura transloca suas reservas para os órgãos reprodutivos, como também ocorre a senescência e degradação da clorofila, evidenciando queda no NDVI.

A Tabela 1 demonstra as correlações entre produtividade e NDVI. Marques Pereira et al. (2021) citam que a correlação de Pearson (r) mede a relação entre duas variáveis quantitativas, sendo que valores negativos as variáveis são inversamente proporcionais e valores positivos diretamente proporcionais. Callegari; Jacques (2008) classificam a correlação entre variáveis em intervalos de 0 e 0.30 como fraca, 0.30 e 0.60 regular, e de 0.60 a 0.90 forte.

Todas as correlações significativas encontradas estão acima de 0.94, ou seja, com forte dependência positiva entre os parâmetros.



Tabela 1. Correlação de Pearson (r) entre a produtividade da cultura da soja e a média do NDVI.

Data da Imagem	Dias Após a Semeadura	NDVI Médio	r
11/01/22	57	0.36	0.87 ^{ns}
22/01/22	68	0.36	0.94*
31/01/22	77	0.40	0.94*
03/02/22	80	0.46	0.97*
15/02/22	92	0.60	0.77 ^{ns}
24/02/22	101	0.54	0.77 ^{ns}
03/03/22	108	0.29	0.74 ^{ns}
15/03/22	120	0.27	0.96*
21/03/22	126	0.20	0.98*

*Significativo a 5% de probabilidade de erro pelo “teste t”

^{ns} Não Significativo a 5% de probabilidade de erro pelo “teste t”

As maiores correlações positivas fortes e significativas se deram aos 68, 77, 80, 120 e 126 DAS. O que chama atenção é que no pico de NDVI aos 92 DAS e 101 DAS as correlações foram as menores e não significativas, ou seja, na maior condição de biomassa da cultura não é o momento ideal de coleta de imagens para predição de produtividade, possivelmente pela menor discrepância do talhão em separar zonas de baixa e alta produtividade devido a saturação do NDVI.

As maiores correlações se deram anteriores aos máximos NDVI, o que permite estimar a produtividade de soja com a utilização do índice via sensoriamento remoto. Antuniassi et al. (2007) expuseram que existe correlação positiva entre os valores de NDVI e a produtividade das culturas.

Em seu trabalho Andrade Júnior et al. (2022) utilizando-se de imagens multiespectrais de drone encontraram uma correlação para o NDVI com rendimento de grãos de 0.76. Valor este abaixo das datas com correlação significativa no presente estudo com média de 0.96, o que demonstra que o uso do NDVI com imagens de satélite é importante ferramenta para predição de produtividade de grãos em soja.

Para as datas de imageamento que obtiveram correlações significativas com a produtividade foram realizadas ajuste de equações lineares visando estimar a produtividade de soja encontradas na Tabela 2. Todas as datas obtiveram elevado coeficiente de determinação, onde o NDVI explicou em média 91.8% da variação da produtividade no talhão estudado. Os dados estão semelhantes o encontrado por Andrade et al. (2022) que utilizando imagens NDVI das fases intermediária e final da cultura e correlacionando com mapa de produtividade observaram o maior coeficiente de determinação de 91%.



Tabela 2. Equações de Regressão Lineares para correlações significativas entre a produtividade da cultura da soja e a média do NDVI.

Data da Imagem	Dias Após Semeadura	Equação Linear	R ²
22/01/2022	68	2280.5*NDVI + 2389.4	0.88*
31/01/2022	77	3061.2*NDVI + 1961.8	0.89*
03/02/2022	80	3234.9*NDVI + 1689.3	0.93*
15/03/2022	120	5258*NDVI + 1783.6	0.93*
21/03/2022	126	4094.8*NDVI + 2350.4	0.96*

*Significativo a 5% de probabilidade de erro pelo “teste F”

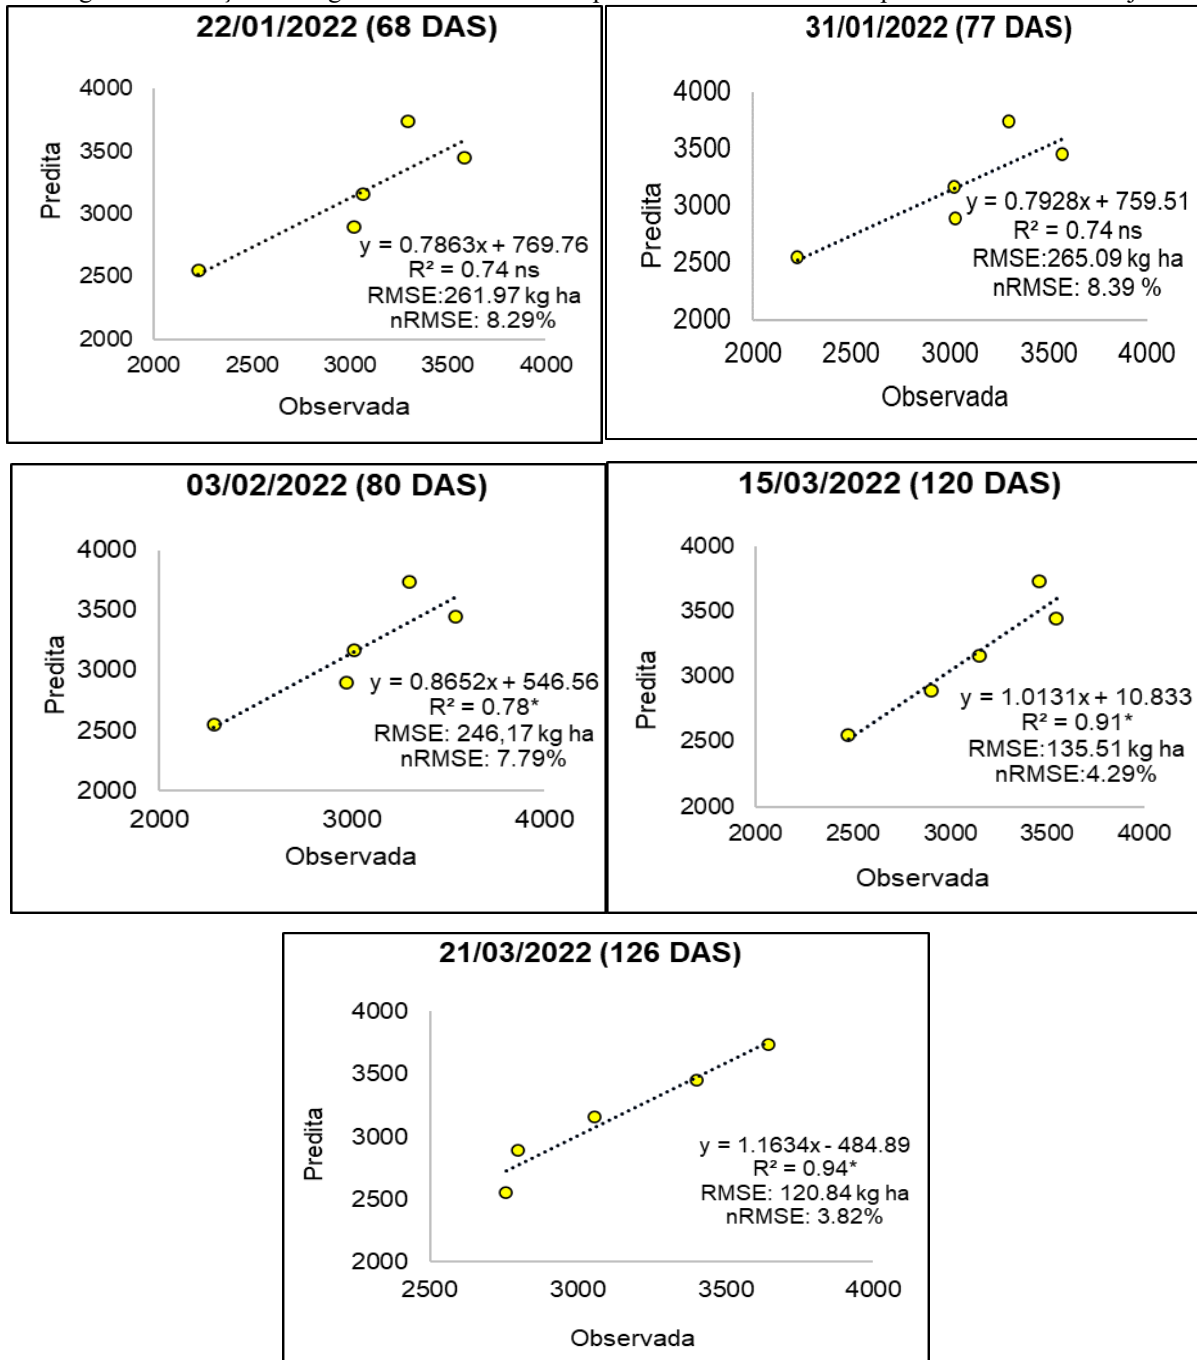
Mercante et al. (2010) utilizando de imagens Landsat 5/TM para estimar a produtividade de soja através de índices de vegetação no oeste do Paraná na safra de 2004/2005, verificaram o melhor desempenho para o coeficiente de determinação de 56,25%. Os valores do presente estudo apresentaram um melhor ajuste, sendo que aos 126 DAS o modelo gerado com NDVI explicou 96% da produtividade.

Os autores acima, citam que em muitas datas o coeficiente de determinação não foi significativo pois houve poluição de nuvens podendo assim ter alterado os valores reais do NDVI da imagem. As imagens coletadas no trabalho com resolução espacial de 3.7 metros e sem nuvens podem ter contribuído para maior preditividade dos modelos.

Para validação dos modelos gerados se fez uso do coeficiente de determinação (R²), o erro quadrático médio (RMSE) e a % do RMSE em relação à média (nRMSE). Verifica-se na Figura 6, que os melhores modelos significativos para predição da produtividade da cultura da soja com NDVI foram os gerados aos 80, 120 e 126 DAS.



Figura 6. Validação das regressões lineares entre a produtividade observada e predita na cultura da soja.



Embora, aos 68 e 77 dias após a semeadura são explicados 74% da predição através do R², estes modelos não foram significativos pelo teste “F”, e, portanto, não se pode afirmar que estes modelos sejam confiáveis para o presente trabalho. Também, estes modelos apresentaram a maior erro de previsão $\pm 263.53 \text{ kg ha}^{-1}$, na média do RMSE e 8.34% de erro da estimativa pelo nRMSE.

Segundo **Maimaitijiang et al. (2020)** a métrica **RMSE** relaciona a magnitude entre os valores reais de campo e os estimados pelos modelos, enquanto o **nRMSE** é uma medida normalizada do RMSE usada para comparar o desempenho de diferentes modelos de regressão. Quanto menor o RMSE melhor é a predição do modelo gerado. De acordo com **Silva et al. (2018)** o nRMSE é excelente,



quando inferior a 10%; bom, entre 10% e 20%; razoável, entre 20% e 30%, e ruim quando superior a 30%.

Os modelos de predição entre produtividade da cultura da soja com NDVI gerados aos 80, 120 e 126 DAS obtiveram nRMSE médio de 5.3% sendo, portanto, um valor excelente pela classificação de Silva et al. (2018). Andrade et al. (2022) em seu estudo encontraram menores nRMSE em seus modelos com erros de previsão de média de 4.34%.

Quanto ao RMSE os dados também se assemelham aos encontrados por Andrade et al. (2022) em que seus modelos utilizando NDVI apresentaram RMSE variando de 153,9 a 160,9 kg ha⁻¹. A média do RMSE dos modelos gerados aos 80, 120 e 126 DAS foi de ± 167.51 kg ha⁻¹ ou 2.79 sacas de 60 kg de soja, demonstrando pela praticidade e antecedência essas datas serem promissoras para medição da produtividade em safras posteriores no talhão estudado.

Analisando apenas a predição aos 126 DAS o nRMSE foi de 3.82% e RMSE de 120.84 kg ha⁻¹, demonstrando alta assertividade do modelo para o talhão estudado. A predição encontrada no trabalho, é superior à de Stepanov et al. (2020) realizado na China para avaliar as relações entre a produtividade da soja e o máximo de NDVI e as variáveis meteorológicas em escala regional no distrito de Khabarovsk os quais encontraram para seu modelo o RMSE foi de 130 kg ha⁻¹.

Considerando os critérios analisados, os modelos aos 80, 120 e 126 DAS mostraram-se promissores, enquadrando-se na categoria excelente de erro proposto por Silva et al (2018) e podem ser aplicados para a previsão da produtividade de grãos de soja no talhão de estudo, podendo no caso dos 80 DAS se prever a produtividade 70 dias anterior a colheita com erro de $\pm 246,17$ kg ha⁻¹.

Os dados demonstraram que é possível estimar a produção de soja através do NDVI com antecedência a colheita, corroborando o descrito por Tola et al. (2017) em que a produtividade pode ser mensurada a partir de índices de vegetação, calculados a partir de imagens multiespectrais. Ainda, Motomiya et al.(2012) citaram que os dados de sensoriamento remoto, pela sua periodicidade conseguem monitorar através de índices de biomassa à produtividade, durante todo o ciclo de desenvolvimento da cultura.

4 CONCLUSÃO

O NDVI possui comportamento exponencial da semeadura a colheita da soja com maiores valores encontrados próximos aos 92 dias após semeadura (DAS) para cultivar DM 5958.

As maiores correlações significativas entre NDVI com a produtividade de grãos estão entre 68 aos 80 DAS e dos 120 a 126 DAS. Período este fora dos valores máximos de NDVI médio encontrados.

Modelos gerados aos 80, 120 e 126 DAS permitiram estimar a produtividade de soja via NDVI com erro médio de ± 167.51 kg ha⁻¹.



Imagens de sensoriamento remoto permitiram prever com antecedência de 70 dias da colheita com precisão de $\pm 246,17 \text{ kg ha}^{-1}$ a produtividade em soja com utilização do NDVI, para o talhão de estudo.

O NDVI com imagens de alta resolução é uma alternativa de mensuração para produtividade da soja.



REFERÊNCIAS

- ALLEN, R. G.; PEREIRA, L.S. 2009. Estimating crop coefficients from fraction of ground cover and height. *Irrigation Science* 28: 17-34.
- ALVINO, F. C. G. et al. 2020. Vegetation indices for irrigated corn monitoring. *Engenharia Agrícola* 40: 322-333.
- AMADO, T.J.C. et al. 2007. Variabilidade espacial e temporal da produtividade de culturas sob sistema plantio direto. *Pesquisa Agropecuária Brasileira* 42: 1101-1110.
- ANDRADE JÚNIOR, A. S. et al. 2022. Predicting soybean grain yield using aerial drone images. *Revista Brasileira de Engenharia Agrícola e Ambiental* 26: 466–476.
- ANDRADE, T. G et al. 2022. Soybean yield prediction using remote sensing in southwestern Piauí state, Brazil. *Revista Caatinga* 35: 105-116.
- AYRES, M. et al. 2007. *Bioestat 5.0 aplicações estatísticas nas áreas das ciências biológicas e médicas*. Belém: IDSM, 364p.
- CALLEGARI-JACQUES, S. M. 2008. *Bioestatística: princípios e aplicações*. Porto Alegre: Artmed, 255 p.
- CONAB - Companhia Nacional de Abastecimento. 2023. Acompanhamento da safra brasileira de grãos 10: 1-96. Disponível em: <https://www.conab.gov.br/info-agro/safras>. Acesso em: 10 abr. 2023.
- FARIAS, P. R. S. et al. 2003. Agricultura de Precisão: Mapeamento da produtividade em pomares cítricos usando geostatística. *Revista Brasileira de Fruticultura* 25: 235-241.
- GIMENEZ, L. M; MOLIN, J.P. 2004. Algoritmo para redução de erros em mapas de produtividade para Agricultura de Precisão. *Revista Brasileira de Agrocomputação* 2: 5-10.
- KUIAWSKI, A.C.M.B. et al. 2017. Vegetation indexes and delineation of management zones for soybean. *Pesquisa Agropecuária Tropical* 47: 168-177.
- LE PAGE, M.; ZRIBI, M. 2019. Analysis and Predictability of Drought in Northwest Africa Using Optical and Microwave Satellite Remote Sensing Products. *Scientific Reports* 9:1-13.
- MAIMAITIJIANG, M. et al. 2020. Soybean yield prediction from UAV using multimodal data fusion and deep learning. *Remote Sensing of Environment* 237: 111599.
- MARQUES PEREIRA, L. et al. 2021. Correlação da produtividade da soja com os atributos químicos do solo e o NDVI. *Revista Brasileira De Agropecuária Sustentável* 11: 430-438.
- MARTELLO, M. et al. 2022. Use of Active Sensors in Coffee Cultivation for Monitoring Crop Yield. *Agronomy* 12: 2118.
- MENEGATTI, L.A.A.; MOLIN, J. P. 2004. Remoção de erros em mapas de produtividade via filtragem de dados brutos, *Revista Brasileira de Engenharia Agrícola e Ambiental* 8: 126-134.
- MERCANTE, E. et al. 2010. Modelos de regressão lineares para estimativa de produtividade da soja no oeste do Paraná, utilizando dados espectrais. *Engenharia Agrícola* 30: 504-517.



- MOTOMIYA, A. V de A. et al. 2012. Mapeamento do índice de vegetação da diferença normalizada em lavoura de algodão. *Pesquisa Agropecuária Tropical* 42: 112-118.
- MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. 2004. Análise espectral e temporal da cultura do café em imagens Landsat. *Pesquisa Agropecuária Brasileira* 39: 223-231.
- PENG, Y. et al. 2017. Assessment of canopy chlorophyll content retrieval in maize and soybean: implications of hysteresis on the development of generic algorithms. *Remote Sensing* 9: 226.
- PLANET. PLANET IMAGERY PRODUCT SPECIFICATIONS, 2022. Disponível em: https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf Acesso em: 20 abr. 2023.
- PRADEBON, L. C. et al. 2023. Soybean adaptability and stability analyzes to the organic system through AMMI, GGE Biplot and mixed models methodologies. *Ciência Rural* 53: e20220262.
- RISSO, J. et al. 2012. Índices de vegetação Modis aplicados na discriminação de áreas de soja. *Pesquisa Agropecuária Brasileira* 47: 1317-1326.
- RODRIGUES, C. P. et al. 2013. NDVI e fluxo de CO₂ em lavoura de soja no Rio Grande do Sul. *Revista Brasileira de Meteorologia* 28: 95-104.
- RODRIGUES, S. A. et al. 2023. Different water availability in the economic water productivity in soybean cultivars. *Revista Ceres* 70: 1-10.
- ROUSE, J. W. et al. 1974. Monitoring vegetation systems in the Great Plains with ERTS. in: 3d ERTS-1 Symposium, NASA, Goddard Space Flight Center, United States, 309-317. Disponível em: <https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf> Acesso em: 15 abr. 2023.
- SANTI, A. L. et al. 2022. Definição de zonas de produtividade em áreas manejadas com agricultura de precisão. *Revista Brasileira De Ciências Agrárias* 8: 510-515.
- SANTOS, O. L. et al. 2018 Análise de índice de vegetação através de imagens obtidas por VANT. *Revista Científica FAESA* 14: 145- 165.
- SILVA D. A. A. da et al. 2015. Perfil de NDVI em estádios de desenvolvimento de soja em função de diferentes plantas de coberturas do solo no Rio Grande do Sul. *Biosfera* 11: 2340.
- SILVA, V. D. P. R. et al. 2018. Calibração e validação do modelo AquaCrop para a cultura da soja sob diferentes níveis de irrigação na região do Matopiba, Brasil. *Ciência Rural* 48: 1-8.
- STEPANOV, A. et al. 2020. Predicting Soybean Yield at the Regional Scale Using Remote Sensing and Climatic Data. *Remote Sensing* 12: 1936.
- TOLA, E. et al. 2017. Characterization of spatial variability of soil physicochemical properties and its impact on Rhodes grass productivity. *Saudi Journal of Biological Sciences* 24: 421-429.
- TSCHIEDEL, M.; FERREIRA, M. F. P. 2022. Introdução a agricultura de precisão: conceitos e vantagens. *Ciência Rural* 32: 159-163