

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP**

**CÂMPUS DE JABOTICABAL**

**RESPOSTA ESPECTRAL: ANÁLISE DE COMPONENTES  
PRINCIPAIS PARA A DIFERENCIAÇÃO DE ARRANJOS  
ESPACIAIS NA SOJA**

**Jamile do Nascimento Santos**

**Engenheira Agrônoma**

**2023**

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP**

**CÂMPUS DE JABOTICABAL**

**RESPOSTA ESPECTRAL: ANÁLISE DE COMPONENTES  
PRINCIPAIS PARA A DIFERENCIAÇÃO DE ARRANJOS  
ESPACIAIS NA SOJA**

**Discente: Jamile do Nascimento Santos**

**Orientador: Prof. Dr. Carlos Eduardo Angeli Furlani**

**Coorientadora: Samira Luns Hatum de Almeida**

Dissertação de mestrado apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para obtenção do título de Mestra em Agronomia (Produção Vegetal).

S237r	<p>Santos, Jamile do Nascimento</p> <p>Resposta espectral: análise de componentes principais para a diferenciação de arranjos espaciais na soja / Jamile do Nascimento Santos. -- Jaboticabal, 2023</p> <p>51 p. : il., tabs., fotos, mapas</p> <p>Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal</p> <p>Orientador: Carlos Eduardo Angeli Furlani Coorientadora: Samira Luns Hatum de Almeida</p> <p>1. Aeronave remotamente pilotada, 2. Análise multivariada, 3. <i>Glycine max</i> (L.) Merr, 4. Índice de vegetação, 5. População de plantas. I. Título.</p>
-------	--

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor.

Essa ficha não pode ser modificada

### **IMPACTO ESPERADO NA SOCIEDADE**

A combinação do monitoramento aéreo utilizando aeronaves remotamente pilotadas e a análise de componentes principais permitirá a identificação precisa dos arranjos espaciais na cultura da soja, levando em consideração a resposta espectral. Essa abordagem resultará em um plantio otimizado, aumentando a produtividade da soja, reduzindo os custos de produção e promovendo práticas de manejo mais sustentáveis na agricultura.

### **EXPECTED IMPACT ON SOCIETY**

The combination of aerial monitoring using remotely piloted aircraft and principal component analysis will allow for precise identification of spatial arrangements in soybean crops, taking into account spectral responses. This approach will result in optimized planting, increasing soybean yield, reducing production costs, and promoting more sustainable agricultural management practices.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal



**CERTIFICADO DE APROVAÇÃO**

TÍTULO DA DISSERTAÇÃO: RESPOSTA ESPECTRAL: ANÁLISE DE COMPONENTES PRINCIPAIS PARA A DIFERENCIAÇÃO DE ARRANJOS ESPACIAIS NA SOJA

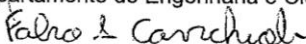
**AUTORA: JAMILE DO NASCIMENTO SANTOS**

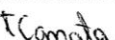
**ORIENTADOR: CARLOS EDUARDO ANGELI FURLANI**

**COORDENADORA: SAMIRA LUNS HATUM DE ALMEIDA**

Aprovada como parte das exigências para obtenção do Título de Mestra em Agronomia (Produção Vegetal), pela Comissão Examinadora:

  
Prof. Dr. CARLOS EDUARDO ANGELI FURLANI (Participação Presencial)  
Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal

  
Prof. Dr. FABIO ALEXANDRE CAVICHIOLI (Participação Presencial)  
Departamento de Agronegócio / FATEC - Taquaritinga/SP

  
Profa. Dra. TATIANA FERNANDA CANATA (Participação Presencial)  
Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal

Jaboticabal, 03 de março de 2023

## **DADOS CURRICULARES DO AUTOR**

**JAMILE DO NASCIMENTO SANTOS**, nascida em Capitão Poço– PA em 22 de janeiro de 1996, filha de Rosilene do Nascimento Santos e José Arnaldo da Silva Santos. Coursou o ensino fundamental na escola Maria do Socorro Ricarte Lopes (2007 – 2011), cursou ensino médio/técnico em segurança do Trabalho na Escola Tecnológica do Estado do Pará (2011-2015) ambas localizadas no município de Tailândia – PA. Ingressou na graduação em 2016, no curso de bacharelado em Engenharia Agrônoma na Universidade Federal rural da Amazonia , Câmpus Capitão Poço. Durante a graduação foi estagiária voluntária por 1 ano no laboratório de Ecofisiologia Vegetal, foi bolsista de Iniciação Científica (CNPq) no projeto Tutor vivo na pimenteira do Reino sob orientação do prof. Dr. Heráclito Eugenio Oliveira. Foi monitora das disciplinas de Metodologia da pesquisa e comunicação Oral e Escrita. No último ano de graduação participou do grupo de sensoriamento remoto, no qual desenvolveu o trabalho de conclusão de curso na área, sob orientação do prof. Dr Fabio Jr. Oliveira. O título de Engenheira Agrônoma foi conquistado no ano de 2021. Ingressou no Mestrado pelo Programa de Pós-Graduação em Agronomia (Produção Vegetal) no ano de 2021, com linha de pesquisa em Agricultura Digital, na Universidade Estadual Paulista “Júlio de Mesquita Filho” Faculdade de Ciências Agrárias e Veterinárias, Câmpus de Jaboticabal – UNESP/FCAV. Integrante do Laboratório de Máquinas e Mecanização Agrícola (LAMMA), localizado no Departamento de Engenharia e Ciências Exatas, desenvolveu trabalhos de pesquisa nas áreas de sensoriamento remoto e agricultura de precisão.

"Queremos ter certezas e não dúvidas, resultados e não experiências, mas nem mesmo percebemos que as certezas só podem surgir através das dúvidas e os resultados somente através das experiências."

Carl Jung

Aos meus pais, Rosa e Arnaldo.

**DEDICO!**

**AGRADECIMENTOS**



Agradeço imensamente à Deus, pela vida, por ter me concedido saúde, força e disposição nos momentos de dificuldades durante a vida e o curso. Sem Ele, nada disso seria possível. À minha família, meus pais, minha base, exemplo de perseverança, apoio e incentivo incondicional. Meu objetivo de vida e poder retribuir tudo que fizeram meus irmãos e eu.

Agradeço à Instituição Universidade Federal Rural da Amazônia, em especial aos meus orientadores da graduação, Dr. Fabio Júnior de Oliveira e Dr. Heráclito Eugenio Oliveira pelas contribuições na minha formação. As amigadas de Capitão Poço, Izadora Mesquita, Odailson Nascimento, Talles Carvalho, M<sup>a</sup> Socorro Santos, Thalia Siqueira, Antônia Erica e Milton Garcia por todo apoio.

A Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal) e a Fazenda de Ensino, Pesquisa e Extensão- FEPE pelo auxílio na condução do experimento. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Ao meu Orientador Prof. Dr. Carlos Eduardo Angeli Furlani, pelos ensinamentos, pela disponibilidade sempre que precisei e por ser um exemplo de profissional. A minha Coorientadora Dra Samira Luns, grata pelo conhecimento e experiências trocadas.

Ao Prof. Dr. Rouverson, pelos ensinamentos profissionais e humanos. Ao secretario Davi Trevisoli e operador de máquinas Valdeci Aparicio “Maranhão” que sempre foram receptivos em compartilhar seus conhecimentos e auxiliar naquilo que for preciso.

A Pioneer sementes, na pessoa do Ronaldo Gonzaga, pela parceria e disponibilidade do material.

Aos companheiros do Laboratório de Máquinas e Mecanização Agrícola (LAMMA), Armando Brito, Bruno Almeida, Jarlyson Bruno, Yara Karine, Marcelo Barbosa, Romário e Tulio Marra pela troca de experiencias. Em especial ao Jean Lucas, Mariana Dias, Vinicius Carreira pelo apoio e amizade nos momentos mais turbulentos. Aos amigos Eduarda, João, Laura e Vanessa por tornarem os dias mais leves. Pôr fim, agradeço a todos que de alguma forma, contribuíram para que fosse possível a concretização dessa etapa em minha formação.

## SUMÁRIO

RESUMO.....	i
ABSTRACT .....	ii
LISTA DE ABREVIATURAS E SIGLAS .....	iii
LISTA DE TABELAS .....	iv
LISTA DE FIGURAS .....	v
CAPÍTULO 1 – Considerações gerais.....	1
1. Introdução.....	1
1.1. Revisão de literatura.....	2
1.1.1. Soja.....	2
1.1.1.2 Arranjo espacial .....	3
1.1.2 Agricultura digital.....	5
1.1.3 Sensoriamento Remoto .....	6
1.1.3.1 Índices De Vegetação (IVs) .....	8
1.1.4 Análise de Componente Principal (PCA) .....	10
Referências .....	11
CAPÍTULO 2 - Resposta espectral: análise de componentes principais para a diferenciação de arranjos espaciais na soja.....	19
2.1. Introdução .....	19
2.2. Material e Métodos .....	20
2.2.1. Área de estudo.....	20
2.2.2. Delineamento experimental, Condução do experimento e avaliação de estande.....	21
2.2.3. Aquisição de Dados Espectrais no Campo com RPA e Processamento de Imagem .....	22
2.2.4. Avaliação de produtividade .....	24
2.2.5. Análise de dados.....	24
2.3. Resultados e Discussão .....	24
2.3.1. Variáveis produtivas.....	24
2.3.2. Resposta espectral na diferenciação dos arranjos.....	26
2.4. Conclusões.....	30
Referências .....	30
Apêndice .....	35

## RESPOSTA ESPECTRAL: ANÁLISE DE COMPONENTES PRINCIPAIS PARA A DIFERENCIAÇÃO DE ARRANJOS ESPACIAIS NA SOJA

### RESUMO

O estudo com sensoriamento remoto na soja, embora importante concentra-se na estimativa ou na predição da produtividade. Entretanto, a produtividade da soja pode variar de acordo com a população de plantas e o espaçamento entre linhas. Dessa forma o objetivo deste estudo foi diferenciar arranjos espaciais de soja a partir de imagens multiespectrais por meio de índices de vegetação. Foram utilizados dois espaçamentos de semeadura: convencional (C) com 0,45 m e linhas duplas intercaladas (D) com duas linhas de 0,30 m por uma de 0,60 m. Além disso, foram adotadas três populações de plantas: P1= 300, P2= 350 e P3= 400 mil plantas ha<sup>-1</sup>. As imagens multiespectrais foram coletadas aos 45, 55, 65,75, 85 e 95 dias após a emergência, os parâmetros avaliados foram: índices de vegetação, bandas espectrais, número de vagens por planta, número de vagens por grão, massa de mil grãos. A análise de componentes principais foi aplicada para diferenciar os arranjos espaciais de soja. Os resultados mostraram que a banda do vermelho e do infravermelho próximo são as bandas espectrais mais responsivas para diferenciação dos arranjos dos 45 aos 75 dias após a emergência. Independentemente dos dias após emergência, o Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação Ajustado ao Solo (SAVI), Índice De Vegetação Não-Linear (NLI) apresentaram a mesma capacidade de diferenciar os arranjos. Essas descobertas fornecem mais informações sobre a obtenção remota da informação do arranjo espacial que auxiliará na tomada de decisão de qual arranjo usar.

**Palavras-chave:** Aeronave remotamente pilotada, Análise multivariada, *Glycine max* (L.) Merr, Índice de vegetação, População de plantas.

## ABSTRACT

The study on remote sensing in soybean cultivation, although important, focuses primarily on estimating or predicting productivity. However, soybean productivity can vary based on plant population and row spacing. Therefore, the objective of this study was to differentiate soybean spatial arrangements using multispectral imagery and vegetation indices. Two seeding spacings were used: conventional (C) with 0.45m between rows, and intercalated double rows (D) with two rows spaced at 0.30m and one row at 0.60m. Additionally, three plant populations were adopted: P1=300, P2=350, and P3=400 thousand plants per hectare. Multispectral images were collected at 45, 55, 65, 75, 85, and 95 days after emergence. The evaluated parameters included vegetation indices, spectral bands, number of pods per plant, number of pods per grain, and thousand grain weight. Principal component analysis was applied to differentiate the soybean spatial arrangements. The results showed that the red and near-infrared spectral bands were the most responsive for differentiating the arrangements from 45 to 75 days after emergence. Regardless of the days after emergence, the Normalized Difference Vegetation Index (NDVI), Soil-Adjusted Vegetation Index (SAVI), and Non-Linear Vegetation Index (NLI) exhibited the same capability to differentiate the arrangements. These findings provide further information on remotely obtaining spatial arrangement information, which will assist in decision-making regarding which arrangement to use.

**Keywords:** Remotely piloted aircraft, Multivariate analysis, *Glycine max* (L.) Merr, Vegetation index, Plant population.

## LISTA DE ABREVIATURAS E SIGLAS

C	Espaçamento convencional de 0,45 m entre linhas
CONAB	Companhia Nacional de Abastecimento
CP1	Espaçamento Convencional entre linhas e população de 300 mil plantas ha <sup>-1</sup>
CP2	Espaçamento Convencional entre linhas e população de 350 mil plantas ha <sup>-1</sup>
CP3	Espaçamento Convencional entre linhas e população de 400 mil plantas ha <sup>-1</sup>
CV	Coeficiente de Variação
D	Espaçamento duplo intercalado de 0,30 m-0,60 m
DAE	Dias Após a Emergência
DP1	Espaçamento intercalado de linhas duplas e população de 300.000 plantas por hectare
DP2	Espaçamento intercalado de linhas duplas e população de 350.000 plantas por hectare
DP3	Espaçamento intercalado de linhas duplas e população de 400.000 plantas por hectare
EL	Espaçamento entre linhas
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FAO	<i>Food and Agriculture Organization of the United Nations</i> - Organização das Nações Unidas para Alimentação e Agricultura
IMEA	Instituto Mato-Grossense de Economia Agropecuária.
IV	Índice de Vegetação
MMG	Massa de mil de grãos
NDVI	<i>Normalized Difference Vegetation Index</i> - Índice de Vegetação Por Diferença Normalizada
NIR	Infravermelho próximo
NLI	<i>Non-Linear Index</i> - Índice de Vegetação Não Linear
NV	Número de grãos por vagens
NVP	Número de vagens por planta
P1	População de 300 mil plantas ha <sup>-1</sup>
P2	População de 350 mil plantas ha <sup>-1</sup>
P3	População de 300 mil plantas ha <sup>-1</sup>
P4M	Phantom 4 multiespectral
PCA	<i>Principal Component Analysis</i> - Análise de Componentes Principais
REDEGE	Região da borda do vermelho
RGB	Red, Green e Blue - vermelho, verde e azul
RPA	<i>Remotely piloted aircraft</i> - aeronaves remotamente pilotadas
SAVI	<i>Soil Adjusted Vegetation Index</i> - Índice de Vegetação Ajustado ao Solo
SR	Sensoriamento remoto
USDA	<i>United States Department of Agriculture</i> -Departamento de Agricultura dos Estados Unidos

## LISTA DE TABELAS

<b>Tabela</b>	<b>página</b>
<b>Tabela 1.</b> Comprimento de onda para bandas presentes no sensor do P4M.....	23
<b>Tabela 2.</b> Índices de vegetação utilizados .....	23
<b>Tabela 3.</b> Valores médios obtidos para o desdobramento da produtividade (kg.ha) em arranjos espaciais na soja.....	24
<b>Tabela 4.</b> Valores médios de número de vagens por planta (NVP), número de grãos por vagem (NV), e massa de 1000 grãos (MMG) para arranjos espaciais da soja. ....	26

## LISTA DE FIGURAS

Figura		página
<b>CAPÍTULO 1</b>		
<b>Figura 1.</b>	Refletância da vegetação saudável e sob estresse, analisada pelo NDVI (NIR: infravermelho próximo; Red: vermelho).....	9
<b>Figura 2.</b>	Valor do fator L de acordo com a densidade da vegetação.....	10
<b>CAPÍTULO 2</b>		
<b>Figura 1</b>	Figura 1. Dados climáticos diários: precipitação (mm), temperatura média (°C) e irradiância solar global (MJ m <sup>-2</sup> ) ocorridas no período da safra de dezembro 2021 a março 2022 de acordo com os dias após a emergência (DAE).....	21
<b>Figura 2</b>	a. Vista superior da área experimental, em que retângulos pretos representam as parcelas e quadrículas amarelas as amostras; b. espaçamento entre linhas da cultura, em que b.1 espaçamento convencional de 0,45 m e b.2 espaçamento duplo intercalado de 0,30 m-0,60 m (D).....	22
<b>Figura 3.</b>	Média e desvio padrão do comportamento espectral dos arranjos espaciais de soja em função dos dias após emergência (DAE). 27	
<b>Figura 4</b>	Figura 4. Análise de componentes principais para arranjos espaciais em bandas espectrais e índices de vegetação de acordo com a data de avaliação. a. 45 DAE; b. 55 DAE; c. 65 DAE; d. 75 DAE; e. 85 DAE; f. 95 DAE.....	28

## **CAPÍTULO 1 – Considerações gerais**

### **1. Introdução**

A soja é uma cultura com mecanismos compensatórios dos seus componentes de produção, com capacidade de adaptação às diferentes condições ambientais e de manejo. O menor espaçamento entre linhas e maior densidade de semeadura tem como benefícios melhorar a interceptação da radiação solar no início do ciclo, diminuir a competição com plantas daninhas e, conseqüentemente, promover o aumento da produtividade, entretanto, entrelinhamento maior e menor densidade de semeadura tem como benefício ao melhor controle de doenças e a redução no custo com sementes. Assim, a decisão quanto à taxa de semeadura e ao entrelinhamento ideais não é simples, pois depende da variedade, severidade de ocorrência de doenças, infestação de plantas daninhas e prevalência de dias com elevada luminosidade sem nuvens etc.

Como alternativa, a tecnologia de sensoriamento remoto possibilita obter informações das plantas de maneira eficiente e segura. A utilização de Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft - RPA*), por exemplo, possibilita obter dados úteis das áreas agrícolas para a tomada de decisão pelos produtores. Para ajudar a minimizar o número de variáveis de campo sem comprometer os dados, novas técnicas analíticas vêm sendo aplicadas, como por exemplo, técnicas de análise de componentes principais. Esta técnica reduz a dimensionalidade dos dados e preserva o máximo de variabilidade possível dentro do conjunto de dados, podendo identificar as diferenças e semelhanças entre os grupos estudados.

Sendo assim, esta pesquisa apresenta abordagem para diferenciar arranjos espaciais por PCA utilizando imagens multiespectrais obtidas por RPA. Essas descobertas beneficiarão os produtores com a obtenção remota da informação do arranjo espacial, para a tomada de decisões visando maximizar o potencial produtivo da soja. No primeiro capítulo é apresentado o referencial teórico que aprofunda o conhecimento sobre o tema, proporcionando embasamento dos resultados obtidos nos capítulos posteriores. No segundo capítulo é apresentado o artigo científico sobre a aplicabilidade de PCA para diferenciar os arranjos espaciais na soja utilizando dados obtidos por sensor multiespectral embarcado em RPA.



## 1.1. Revisão de literatura

### 1.1.1. Soja

A soja [ *Glycine max* (L.) Merrill.] é uma planta herbácea, família Fabaceae (Leguminosae) (NEPOMUCENO; FARIAS; NEUMAIER, 2021). A cultura tem centro de origem no nordeste da China, com domesticação por volta do século XI A.C. Chegou ao Brasil com os imigrantes japoneses em 1908. A partir da década de 1970 observou-se a expansão do seu cultivo e a soja tornou-se um importante produto brasileiro de exportação (GAZZONI, 2018). É uma das culturas de campo mais cultivadas, plantada em 130 milhões de hectares. Entre os países produtores, o Brasil é o maior produtor, e maior exportador, seguido pelos Estados Unidos, Argentina, China, Paraguai e Índia (USDA, 2022).

A soja é amplamente utilizada, como matéria-prima para a indústria de óleo e farelo. O farelo, rico em proteína é utilizado principalmente para produção de rações para animais, sendo esse o principal emprego econômico da soja. Por sua vez, o óleo é utilizado para produção de óleo refinado, gorduras hidrogenadas, margarinas, maionese dentre outros produtos (CARRÃO-PANIZZI et al., 2021). Também tem sido utilizado em produtos industriais como tintas, lubrificantes, solventes, plásticos e resinas (GAZZONI, 2018). Além de principal matéria- prima para produção de biodiesel (YONG; WU, 2022). A produtividade da cultura pode variar de acordo com a disponibilidade de água, fertilização e arranjo espacial. Em condições de sequeiro, a produtividade varia entre 1.500 e 2.500 kg.ha<sup>-1</sup>. Em cultivos irrigados a produtividade situa-se entre 2.500 e 3.500 kg.ha<sup>-1</sup> (FAO, 2022).

No Brasil, foram semeados 41.452 mil hectares na safra 2021/2022, 4,9% superior ao do último levantamento. Foram incluídas áreas em Mato Grosso, Goiás e Bahia, e redução de área no Maranhão. A produção nacional de soja na safra 2021/22 foi de 125.55 milhões de toneladas, sendo 9,9% inferior ao da safra 2020/21, refletindo o déficit hídrico em novembro e dezembro, influenciado pelo fenômeno La Niña na Região Sul, São Paulo e em Mato Grosso do Sul (CONAB, 2022). Apesar da queda geral, os estados de Mato Grosso e Goiás registraram as maiores produtividades médias da história (IMEA, 2022). Os sojicultores mato-grossenses alcançaram média de 3.663 kg.ha<sup>-1</sup>; já os goianos surpreenderam com um desempenho recorde de 3.958

kg.ha<sup>-1</sup> e superaram o volume total produzido por Rio Grande do Sul e Paraná que foi de 1.530 kg.ha<sup>-1</sup> e 2.131 kg.ha<sup>-1</sup> respectivamente (EMBRAPA, 2022).

Estima-se que a produção global de soja para 2022/23 diminua devido as reduções na produção de soja da Argentina, Estados Unidos e Uruguai, mas que são parcialmente compensadas pelo aumento da produção no Brasil e na China. Espera-se que o clima excepcionalmente seco nas principais províncias produtoras de soja na Argentina afete a área e a produtividade da soja (USDA, 2022). No Brasil, a estimativa de produção são 152.712 mil toneladas, atribuído as chuvas volumosas e abrangentes nas principais regiões produtoras e ao aumento de 4,7% da área semeada, em relação à estimativa anterior, para 43,459 mil hectares (CONAB, 2023).

### **1.1.1.2 Arranjo espacial**

A semeadura é um dos fatores mais importantes para a produção agrícola (LI; FENG; JIANG, 2022). Dessa forma, o primeiro passo dos agricultores é realizar o planejamento de implantação do cultivo, levando em consideração, o aumento nos preços dos insumos no cenário pandêmico. Por exemplo, o custo variável corresponde a 91,17% do custo total da produção. Os principais fatores que contribuem para um custo variável elevado são: sementes transgênicas, fertilizantes, fungicidas, herbicidas e inseticidas, pois apresentam variabilidade ampla de preço ao longo do ano (SILVA; DOBASHI, 2022).

Entre as práticas de manejo, o arranjo de plantas, seja por variação da população de plantas ou do espaçamento entre linhas, deve ser enfatizado, pois tem o poder de reduzir o consumo de sementes e, conseqüentemente, o custo total de produção (CORRENDO et al., 2022; LAMICHHANE et al., 2020). A soja apresenta grande plasticidade em resposta ao arranjo espacial da planta, com capacidade de adaptação às diferentes condições ambientais e de manejo, mas que pode afetar o número de ramos, vagens, grãos por planta e diâmetro do caule, todos que são inversamente proporcionais à população (SILVA et al., 2019).

A densidade de semeadura necessária para obter o rendimento ótimo é, em geral, menor do que a indicada pelos melhoristas de cultivares quando as condições ambientais (por exemplo, temperatura, umidade, radiação solar e fotoperíodo) são favoráveis ao crescimento das plantas (CORRENDO et al., 2022). A população de

semeadura, pode alterar a distribuição das raízes na área, a competição intraespecífica por água, luz e nutrientes, influenciando o crescimento da planta, a arquitetura do dossel, o manejo fitossanitário e a produtividade de grãos (JUNIOR et al., 2018; WERNER et al., 2017; ZHOU; CHEN; OUYANG, 2015). No entanto, existe um limite na população de plantas, um ponto ótimo, abaixo do qual as plantas de soja não podem produzir crescimento compensatório e, portanto, o rendimento é penalizado. Por outro lado, populações de plantas de soja acima do limite, aumentam o risco de acamamento e desenvolvimento de doenças (CARCIOCHI et al., 2019).

A absorção de recursos é amplamente condicionada pela sua disponibilidade no ambiente e pela distribuição dos indivíduos no espaço, esta última pode ser modificada a partir de diferentes combinações de espaçamento entre fileiras e densidades de plantas (BERTRAM; CHIACCHIERA; ANGELETTI, 2020). A redução do espaçamento entre linhas e o aumento da distância entre as plantas da linha otimizam a utilização de fatores de produção como a água, a luz e os nutrientes devido à maior ou menor adaptação da cultura ao ambiente, devido às variações morfológicas e genéticas apresentadas pelos atuais híbridos. Porém o aumento do espaçamento entre linhas pode aumentar a competição com plantas daninhas (FERREIRA et al., 2021).

No Brasil, o espaçamento de linhas tradicionalmente utilizado na semeadura da soja é de 0,45 m ou 0,50 m (NEPOMUCENO; FARIAS; NEUMAIER, 2021). No entanto, as linhas estreitas, duplas e cruzadas são opções pouco exploradas. Um dos objetivos da utilização do espaçamento estreito entre fileiras é reduzir o tempo que a cultura intercepta a maior parte da radiação solar, otimizando a capacidade fotossintética do dossel além de propiciar um número maior de filas por hectares e consequente maior número de plantas (FERREIRA et al., 2019).

Na última década, ocorreram mudanças significativas na produção brasileira de soja, como mudanças morfológicas e fisiológicas de cultivares, aumento das expectativas de rendimento de grãos, antecipação de épocas de semeadura para reduzir a incidência de doenças e pragas (REIS et al., 2019). Isso leva a uma atualização das pesquisas voltadas para o arranjo espacial das plantas, visando aumentar a produtividade de grãos e a rentabilidade da cultura. Assim, têm sido estudado a interação entre populações e espaçamentos de linhas (SILVA et al., 2019).

Estudo de populações de plantas e cultivares de sojas (FRANÇA et al., 2021), populações reduzidas (WERNER et al., 2021a) e superpopulações. Além de espaçamento estreito entre linha (CARMO et al., 2018), espaçamento largo (ANDRADE et al., 2019), linhas cruzadas (ROCHA et al., 2018) e linhas duplas com espaçamento alternado, uma larga e outra estreita (JUNIOR et al., 2018).

### **1.1.2 Agricultura digital**

A agricultura digital é uma abordagem que utiliza tecnologias digitais avançadas para possibilitar a tomada de decisões orientadas por dados em diferentes operações agrícolas (LIOUTAS; CHARATSARI, 2020). Isso destaca a importância do uso de sensores para coletar informações, análise de grandes volumes de dados para *insights* relevantes e aplicação de técnicas de computação em nuvem para processamento e armazenamento eficiente desses dados (REDHU et al., 2022).

No monitoramento e mapeamento de culturas usa-se plataformas de coleta de dados como satélites, RPAs equipados com sensores e câmeras para acompanhar o desenvolvimento da lavoura (REJEB et al., 2022). Esses sensores podem coletar dados sobre a saúde das plantas, identificar doenças ou pragas, mapear a distribuição de nutrientes no solo e detectar áreas com estresse hídrico (VASAVI; PUNITHA; VENKAT NARAYANA RAO, 2022). Esses dados são analisados para fornecer informações separadas sobre as necessidades de cada área específica do campo. Os agricultores podem, então, aplicar fertilizantes, pesticidas e irrigação de forma mais precisa e eficiente, cuidando e minimizando os impactos ambientais (GUPTA et al., 2022; SISHODIA; RAY; SINGH, 2020).

Com o avanço da tecnologia, os agricultores têm acesso a uma quantidade enorme de dados, como informações meteorológicas, históricos de produção, dados de sensores e imagens de satélite (SAN EMETERIO DE LA PARTE et al., 2023). Esses dados podem ser analisados utilizando técnicas de aprendizado de máquina e inteligência artificial para identificar padrões, prever safras, otimizar o uso de insumos e melhorar a tomada de decisões agrícolas (RAIMUNDO; GLORIA; SEBASTIAO, 2021; DEVI; SARMA; LASKAR, 2023).

As plataformas digitais podem conectar produtores, fornecedores de insumos agrícolas e compradores, facilitando a aceitação do produto a ser negociado. Os

agricultores podem usar essas plataformas para encontrar compradores, comparar preços, acessar informações de mercado e gerenciar seus negócios de forma mais eficiente (GENG; REN; WANG, 2007).

A agricultura digital na produção de soja tem o potencial de melhorar a produtividade, reduzir os custos, minimizar os impactos ambientais e otimizar o uso de recursos. No entanto, é importante lembrar que a implementação dessas tecnologias requer investimentos em infraestrutura, capacitação dos agricultores e acesso confiável à conectividade e energia elétrica nas áreas rurais.

### **1.1.3 Sensoriamento Remoto**

O Sensoriamento Remoto (SR) pode ser definido como a ciência de adquirir e medir informações de certas propriedades de fenômenos, objetos ou materiais sem entrar em contato direto com eles (JENSEN, 2009). O registro das informações via SR ocorre através da interação do alvo estudado com a radiação eletromagnética (REM) em diferentes comprimentos de onda nas regiões do visível, infravermelho por meio de sensores ópticos (OMIA et al., 2023). Os sensores ópticos podem ser classificados em ativos ou passivos. Os sensores ativos irradiam energia artificial para monitorar a superfície terrestre ou características atmosféricas. Por exemplo, radar e sensores a laser, já o sensor passivo, não emitem sua própria radiação, recebem luz natural e a radiação de calor refletida pela superfície da Terra, como por exemplo câmeras (KUNDU et al., 2021). Os sensores são acoplados em diferentes plataformas, orbitais (satélites), aéreas (aeronaves de alta, média e baixa altitudes) e podem ser terrestres (campo e laboratório) (SOUZA; BAILO; NEVES, 2017).

A escolha do sensor é definida de acordo com os objetivos a serem alcançados. Devendo ser levado em consideração a resolução espacial, radiométrica espectral e temporal. A resolução espacial refere-se ao tamanho do menor elemento de uma imagem (*pixel*), correspondendo ao tamanho do menor objeto que poderá ser identificado naquela imagem. Já a resolução radiométrica se refere à menor variação de intensidade possível de ser detectada pelo sensor, representada pelo número de níveis dos valores numéricos dos pixels. A resolução espectral refere-se ao número de bandas e à largura da faixa espectral de cada banda. Por fim, a resolução temporal é relacionada ao tempo que o mesmo alvo leva para ser revisitado pelo sensor. Se o

fim pretendido para a análise, for adquirir informação em grandes áreas, recomenda-se satélite pois geralmente cobrem uma área muito mais ampla e, portanto, têm aplicações de maior escala, porém sofrem interferências influência dos fatores que compõem a atmosfera terrestre além do menor tempo de revisita, com o período de visita fixo de determinado local. As plataformas aéreas também podem obter informações de grandes áreas, no entanto, com o ganho em termos de resoluções espacial e temporal, são as mais utilizadas em nível local (VILLAR; ROSAS; PINTO, 2022).

Na agricultura, conhecer as características espectrais da vegetação pode contribuir para a detecção de padrões normais ou anormais que tendem a ocorrer nos cultivos. A interação entre a radiação eletromagnética e a vegetação ocorre de três formas: absorção, transmissão e reflexão, que sofrem alterações de acordo com as propriedades físico-químicas da planta. A absorção ocorre através de suas estruturas fotossintetizantes, principalmente as folhas pela presença da clorofila, xantofila e caroteno, na região do visível (400 nm a 720 nm) nos comprimentos de onda do azul e do vermelho, refletindo no comprimento de onda da região do verde, sendo responsável pela cor verde intensa dos vegetais. A maior reflectância ocorre na região do infravermelho próximo (entre 700 nm e 1300 nm), onde as folhas verdes saudáveis apresentam altos valores de reflectância, alta transmitância e baixa absorbância (FORMAGGIO; SANCHES, 2017; HORNING, 2019).

Entre as principais aplicações do SR cabe destacar a sua importância na agricultura de precisão (AP), que leva em consideração a variabilidade existente na lavoura, para melhorar o uso de recursos com base na eficiência, produtividade, qualidade, rentabilidade, e sustentabilidade da produção agrícola, incluindo a prática de manejo certo, na hora certa, com a quantidade certa de insumos e no lugar certo (GUPTA et al., 2022; SISHODIA; RAY; SINGH, 2020). A dinâmica de comportamento fenológico da vegetação ao longo do ciclo, é elemento de significativa relevância para a extração de informações de interesse agrícola a partir de SR, destacando o perfil da cultura no decorrer do tempo. Enquanto as quantidades de recobrimento vegetal sobre a superfície do solo variam, as respostas espectrais também acompanha essas variações (FORMAGGIO; SANCHES, 2017; ZHANG et al., 2022).

Devido à crescente acessibilidade em termos de flexibilidade, funções de automação no sensoriamento aéreo (por exemplo, navegação e controle de voo),

captura de imagens com resolução espacial de centímetros, e menor custo quando comparado satélites de alta resolução espacial e que são pagos, as Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft* - RPA), estão ganhando popularidade cada vez maior na agricultura (SU et al., 2023). Na agricultura, existem diversas áreas de aplicação de RPA, como monitoramento de culturas e crescimento, estimativa de rendimento, avaliação de estresse hídrico, pulverização aérea de precisão e detecção de ervas daninhas, pragas e doenças dentre outros (REJEB et al., 2022).


As RPAs estão disponíveis com diferentes especificações, equipamentos, tamanhos, alcance e formas. No mercado, as RPAs estão presentes com diferentes números de rotores, onde destacam-se na agricultura os de asa fixa e rotor. O RPA de asa fixa é baseado em asa, corpo principal, motor e hélice, ele requer treinamento extensivo baseado em habilidades para operar e podem se equilibrar verticalmente no ar por cerca de dezesseis horas, mas não podem se mover para trás, pairar ou girar. Assim, eles não são úteis para algumas tarefas, como fotografia aérea (MAIRAJ; BABA; JAVAID, 2019). A RPA de rotor único tem uma estrutura de voo mais robusta, proporcionando uma capacidade de voar em qualquer local no campo sem exigir requisitos de decolagem e pouso, além de menor custo que um RPA de asa fixa. É comumente usado para mapeamento em áreas menores (MOHSAN et al., 2022).

Além disso, uma RPA pode ser equipada por uma variedade de sensores. Os sensores que trabalham na luz visível, vermelho, verde e azul (*Red, Green* e *Blue-RGB*) são câmeras ópticas ou visuais, como por exemplo câmeras monoculares e estéreo. Eles capturam imagens do ambiente ao redor e objetos para fornecer informações valiosas. As vantagens das câmeras são seu tamanho pequeno, peso, baixo consumo de energia, flexibilidade e facilidade de montagem (KÓTA; ZSEDROVITS; NAGY, 2019). As desvantagens de usar tais sensores incluem sua alta sensibilidade às condições climáticas, falta de clareza da imagem, sensibilidade aos níveis de iluminação e contraste de cor do fundo (MORENO; ORTEGA; MORENO, 2022). Os sensores multiespectrais coletam dados de pelo menos um filtro além da faixa espectral do visível, podendo ser no espectro do infravermelho próximo (*NIR*) ou região da borda do vermelho (*RedEdge*) (XIE; YANG, 2020).

### **1.1.3.1 Índices De Vegetação (IVs)**

Para caracterizar a relação entre vegetação e radiação eletromagnética, os índices de vegetação (IVs) são produtos amplamente utilizados (DA SILVA ANDREA et al., 2023). Os IVs são capazes de caracterizar a dinâmica temporal e o vigor da vegetação agrícola por meio de expressões matemáticas das reflectâncias em várias faixas espectrais da radiação eletromagnética (RHYMA et al., 2020). Entre os IVs, Índice de Vegetação Por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI) é um dos mais usados por vários estudos e aplicação na agricultura. O NDVI utiliza a diferença normalizada das bandas do vermelho e do infravermelho próximo. O NDVI explora esse contraste amplificando o sinal da vegetação. Sendo um importante indicador de quantidade e qualidade da massa verde na superfície da vegetação (JENSEN, 2009; ROUSE et al., 1974).

O cálculo do NDVI resulta uma imagem índice que varia entre -1 e 1, de acordo com a superfície estudada. Valores próximo a 1 são associados a plantas saudáveis, com maior biomassa e vigor da vegetação. Situações de estresses, senescência e tendem a causar redução no NDVI (Figura 1), valores mais próximos a zero podem ser associados a outros alvos, como solo exposto, enquanto valores negativos estão associados a espelhos d'água (VILLAR; ROSAS; PINTO, 2022)



**Figura 1.** Refletância da vegetação saudável e sob estresse, analisada pelo NDVI (NIR: infravermelho próximo; Red: vermelho).

**Fonte:** Adaptado, Giovanini, A., (2021).

O Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index* - SAVI) é descrito como um ajuste da equação do NDVI, criado para atenuar os efeitos da reflectância solo sob a densidade de vegetação destacando as respostas



espectrais da cultura analisada, adicionando a constante de ajuste de solo, o fator  $L$  na equação do NDVI (HU et al., 2023; HUETE, 1988). Huete (1988) definiu que para o fator ajustado ao solo ( $L$ ), o valor 0,25 é indicado para vegetação densa; 0,50 para vegetação com densidade intermediária e para vegetação com baixa densidade o valor 1 é indicado (Figura 2).



**Figura 2.** Valor do fator  $L$  de acordo com a densidade da vegetação.

**Fonte:** ANDRADE,2020.

Levando em consideração que os fenômenos agrícolas não seguem um comportamento padrão, ou seja, são não-lineares, Goel e Qin (1994) utilizaram o Índice de Vegetação Não Linear (*Non-Linear Index-NLI*). O NLI lineariza a relação com parâmetros de superfície que tendem a ser não-lineares e podem apresentar melhores correlações com fenômenos agrícolas, quando comparados com IV lineares (GEORGE et al., 2018).

#### 1.1.4 Análise de Componente Principal (PCA)

A análise de componente principal (*Principal Component Analysis- PCA*) é uma técnica multivariada de modelagem da estrutura de covariância. A análise é mais conhecida por realizar a redução de dimensionalidade através do qual os dados multidimensionais são reduzidos a um espaço de dimensão inferior, mantendo a maioria das informações úteis (HONGYU; SANDANIELO; JUNIOR, 2016; LIU et al., 2022). A PCA transforma linearmente um conjunto de variáveis, inicialmente correlacionadas entre si, e as ordena em um gráfico em que o número de eixos, também chamados de componentes (PCs) varia de acordo com os dados (LIMA et al., 2022).

O primeiro componente principal corresponde à direção ao longo da qual as amostras apresentam a maior variação espectral; o segundo componente principal é a direção não correlacionada com o primeiro componente ao longo do qual as

amostras apontam para a segunda variação mais alta e assim por diante, onde pelo menos 80% da variância total devem ser explicadas pelos primeiros e o segundo componentes principais (ABDI, 2010; JOLLIFFE; CADIMA, 2016). Os autovetores são conjuntos de valores que representam o peso de cada variável original sobre cada componente. A correlação de carga de cada PCA, expressa em correlação de coeficiente de Pearson ( $r$ ). Para cada componente, todas as variáveis tem um conjunto de autovetores correspondentes, e quanto mais próximo de +1,0 ou -1,0 está o autovetor, mais importante é a variável para o componente (FURLANETTO et al., 2021).

As bandas espectrais, muitas delas são altamente correlacionadas e, portanto, uma redução de dimensão ou método de seleção de comprimento de onda é essencial para selecionar aqueles comprimentos de onda sensíveis ao objeto de interesse (LU et al., 2020; SANTOS-RUFO et al., 2020). No caso de imagens multiespectrais, a seleção de características é o processo de identificação de um subconjunto de bandas de ondas informativas na tentativa de reduzir a dimensionalidade e melhorar a precisão na análise da imagem, que é uma tarefa desafiadora e que requer conhecimento prévio dos dados disponíveis (JIA et al., 2020).

## Referências

- ABDI, H. Partial least squares regression and projection on latent structure regression (PLS Regression). **WIREs Computational Statistics**, [s. l.], v. 2, n. 1, p. 97–106, 2010.
- ANDRADE, F.; NÓBREGA, J.; ZUFFO, A.; JUNIOR, V.; RAMBO, T.; SANTOS, A. Características Agronômicas e produtivas da soja cultivada em plantio convencional e cruzado. **Revista de Agricultura (Piracicaba)**, [s. l.], v. 91, p. 81–91, 2016.
- BERTRAM, N. A.; CHIACCHIERA, S.; ANGELETTI, F. R. Effect of the pearl millet space arrangement in halo-hydromorphic environments. **RIA, Revista de Investigaciones Agropecuarias**, [s. l.], v. 46, n. 3, p. 314–322, 2020.
- CARCIOCHI, W. D.; SCHWALBERT, R.; ANDRADE, F. H.; CORASSA, G. M.; CARTER, P.; GASPAR, A. P.; SCHMIDT, J.; CIAMPITTI, I. A. Soybean Seed Yield Response to Plant Density by Yield Environment in North America. **Agronomy Journal**, [s. l.], v. 111, n. 4, p. 1923–1932, 2019.
- CARMO, E. L. Do; BRAZ, G. B. P.; SIMON, G. A.; SILVA, A. G. Da; ROCHA, A. G. C. Desempenho agronômico da soja cultivada em diferentes épocas e distribuição de plantas. **Revista de Ciências Agroveterinárias**, [s. l.], v. 17, n. 1, p. 61–69, 2018.

CARRÃO-PANIZZI, M. C.; PIRES, J. L. F.; STRIEDER, M. L.; LEITE, R. S. Teores de óleo e proteína em genótipos de soja em diferentes situações de manejo. [s. l.], 2021.

**CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO.** : n. 4 quarto levantamento. Brasília, DF. Disponível em: <<http://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>. Acesso em: 27 jan. 2023.

**CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. Safra Brasileira de Grãos, Decimo segundo Levantamento - Safra 2021/22.** 12. ed. [s.l.] : Superintendência de Marketing e Comunicação (Sumac) Gerência de Eventos e Promoção Institucional (Gepin), 2022. v. 9 Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos>>

CORRENDO, A.; MCARTOR, B.; PRESTHOLT, A.; HERNANDEZ, C.; KYVERYGA, P. M.; CIAMPITTI, I. A. Interactive soybean variable-rate seeding simulator for farmers. **Agronomy Journal**, [s. l.], v. 114, n. 6, p. 3554–3565, 2022.

DA SILVA ANDREA, M. C.; DE OLIVEIRA NASCIMENTO, J. P. F.; MOTA, F. C. M.; DE SOUZA OLIVEIRA, R. Predictive framework of plant height in commercial cotton fields using a remote sensing and machine learning approach. **Smart Agricultural Technology**, [s. l.], v. 4, p. 100154, 2023.

**Dados econômicos - Portal Embrapa Soja.** 2022. Disponível em: <<https://www.embrapa.br/en/soja/cultivos/soja1/dados-economicos>>. Acesso em: 26 jan. 2023.

FERREIRA, A. S.; BALBINOT, A. A., Jr; WERNER, F.; ZUCARELI, C. Yield performance of soybean cultivars with indeterminate growth habits in response to plant spatial arrangement. **Semina: Ciências Agrárias**, [s. l.], v. 40, n. 6, p. 2905–2916, 2019.

FERREIRA, L. L.; MENDES, S.; CARVALHO, I. R.; CONTE, G. G.; LEAL, F. S.; SANTOS, N. S. C.; SILVA, J. G.; FERNANDES, M. S.; PEREIRA, A. I. A.; CURVELO, C. R. S.; HUTRA, D. J. Spatial arrangement and its implications in the yield of maize cultivars. **Genetics and Molecular Research**, [s. l.], v. 20, n. 1, 2021.

FORMAGGIO, R.; SANCHES, I. D. **Sensoriamento remoto em agricultura.** São Paulo: Oficina de Textos, 2017.

FRANÇA, E. E.; SILVA, G. C. Da; VIANA DE ARAÚJO, M. E.; TEIXEIRA, I. R.; CORRÊA, P. C.; GUERRA DA SILVA, A.; FRANÇA, E. E.; SILVA, G. C. Da; VIANA DE ARAÚJO, M. E.; TEIXEIRA, I. R.; CORRÊA, P. C.; GUERRA DA SILVA, A. Agronomic and physiological characteristics of soybean cultivars and their seeds according to plant population. **Agronomía Colombiana**, [s. l.], v. 39, n. 2, p. 177–186, 2021.

FURLANETTO, R. H.; RAFAEL NANNI, M.; GUILHERME TEIXEIRA CRUSIOL, L.; SILVA, G. F. C.; JUNIOR, A. D. O.; SIBALDELLI, R. N. R. Identification and quantification of potassium (K<sup>+</sup>) deficiency in maize plants using an unmanned aerial

vehicle and visible / near-infrared semi-professional digital camera. **International Journal of Remote Sensing**, [s. l.], v. 42, n. 23, p. 8783–8804, 2021.

GAZZONI, D. L. A soja no Brasil é movida por inovações tecnológicas. **Ciência e Cultura**, [s. l.], v. 70, n. 3, p. 16–18, 2018.

GENG, S.; REN, T. -z.; WANG, M. -h. Technology and Infrastructure Considerations for E-Commerce in Chinese Agriculture. **Agricultural Sciences in China**, [s. l.], v. 6, n. 1, p. 1–10, 2007.

GEORGE, R.; PADALIA, H.; SINHA, S. K.; KUMAR, A. S. Evaluation of the Use of Hyperspectral Vegetation Indices for Estimating Mangrove Leaf Area Index in Middle Andaman Island, India. **Remote Sensing Letters**, [s. l.], v. 9, n. 11, p. 1099–1108, 2018.

GIOVANINI, A. **Índices de Vegetação? Adenilson Giovanini**, 2021. Disponível em: <<https://adenilsongiovanini.com.br/blog/indices-de-vegetacao-o-que-sao-e-como-utilizar/>>. Acesso em: 25 Abril. 2023.

GOEL, N. S.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and Fpar: A computer simulation. **Remote Sensing Reviews**, [s. l.], v. 10, n. 4, p. 309–347, 1994.

GUPTA, D.; GUJRE, N.; SINGHA, S.; MITRA, S. Role of existing and emerging technologies in advancing climate-smart agriculture through modeling: A review. **Ecological Informatics**, [s. l.], v. 71, p. 101805, 2022.

HONGYU, K.; SANDANIELO, V. L. M.; JUNIOR, G. J. de O. Análise de Componentes Principais: Resumo Teórico, Aplicação e Interpretação. **E&S Engineering and Science**, [s. l.], v. 5, n. 1, p. 83–90, 2016.

HORNING, N. Remote Sensing. Em: FATH, B. (Ed.). **Encyclopedia of Ecology (Second Edition)**. Oxford: Elsevier, 2019. p. 404–413.

HU, L.-X.; FAN, S.; MA, Y.; LIU, X.-X.; BAO, W.-W.; GUO, Y.; HU, L.-W.; CHEN, G.; ZENG, X.-W.; ZOU, Z.; YANG, B.-Y.; MA, J.; YANG, Z.; CHEN, Y.-J.; DONG, G.-H. Associations between greenspace surrounding schools and lipid levels in Chinese children and teenagers. **Environmental Pollution**, [s. l.], v. 317, p. 120746, 2023.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, [s. l.], v. 25, n. 3, p. 295–309, 1988.

**IMEA-INSTITUTO MATO GROSSENSE DE ECONOMIA AGROPECUÁRIA**  
relatorios de mercado soja. 2022.

JENSEN, John. R. **Sensoriamento Remoto Do Ambiente - Uma Perspectiva em Recursos Terrestres - John R. Jensen PDF | PDF | Geographic Information System | Geomatics.** 2009. Disponível em: <<https://www.scribd.com/document/456069018/Sensoriamento-Remoto-do->

Ambiente-Uma-Perspectiva-em-Recursos-Terrestres-John-R-Jensen-pdf>. Acesso em: 29 jan. 2023.

JIA, B.; WANG, W.; NI, X.; LAWRENCE, K. C.; ZHUANG, H.; YOON, S.-C.; GAO, Z. Essential processing methods of hyperspectral images of agricultural and food products. **Chemometrics and Intelligent Laboratory Systems**, [s. l.], v. 198, p. 103936, 2020.

JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, [s. l.], v. 374, n. 2065, p. 20150202, 2016.

JUNIOR, A. A. B.; OLIVEIRA, M. C. N. De; EMBRAPA SOYBEAN, RODOVIA CARLOS JOÃO STRASS, DISTRITO DE WARTA, CEP 86001-970, LONDRINA, PARANÁ STATE, BRAZIL; Z. Analysis of phenotypic plasticity in indeterminate soybean cultivars under different row spacing. **Australian Journal of Crop Science**, [s. l.], v. 12, n. 04, p. 648–654, 2018.

KÓTA, F.; ZSEDROVITS, T.; NAGY, Z. Sense-and-avoid system development on an FPGA. Em: 2019 INTERNATIONAL CONFERENCE ON UNMANNED AIRCRAFT SYSTEMS (ICUAS) 2019, **Anais...** . Em: 2019 INTERNATIONAL CONFERENCE ON UNMANNED AIRCRAFT SYSTEMS (ICUAS). [s.l: s.n.]

KUNDU, R.; DUTTA, D.; NANDA, M. K.; CHAKRABARTY, A. Near Real Time Monitoring of Potato Late Blight Disease Severity using Field Based Hyperspectral Observation. **Smart Agricultural Technology**, [s. l.], v. 1, p. 100019, 2021.

KUSS, R. C. R.; KÖNIG, O.; DUTRA, L. M. C.; BELLÉ, R. A.; ROGGIA, S.; STURMER, G. R. Populações de plantas e estratégias de manejo de irrigação na cultura da soja. **Ciência Rural**, [s. l.], v. 38, p. 1133–1137, 2008.

LAMICHHANE, J. R.; CONSTANTIN, J.; SCHOVING, C.; MAURY, P.; DEBAEKE, P.; AUBERTOT, J.-N.; DÜRR, C. Analysis of soybean germination, emergence, and prediction of a possible northward establishment of the crop under climate change. **European Journal of Agronomy**, [s. l.], v. 113, p. 125972, 2020.

LI, D.; BAI, D.; TIAN, Y.; LI, Y.-H.; ZHAO, C.; WANG, Q.; GUO, S.; GU, Y.; LUAN, X.; WANG, R.; YANG, J.; HAWKESFORD, M. J.; SCHNABLE, J. C.; JIN, X.; QIU, L.-J. Time series canopy phenotyping enables the identification of genetic variants controlling dynamic phenotypes in soybean. **Journal of Integrative Plant Biology**, [s. l.], v. n/a, n. n/a, 2022. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/jipb.13380>>. Acesso em: 24 jan. 2023.

LI, Q.; FENG, J.; JIANG, W. DESIGN AND EXPERIMENT ON PRECISION SEED METERING DEVICE FOR NARROW-ROW AND DENSE PLANTING OF SOYBEAN. **INMATEH Agricultural Engineering**, [s. l.], p. 353–363, 2022.

LIMA, A. M. F.; DANIEL, C. R.; PACHECO, M. T. T.; DE BRITO, P. L.; SILVEIRA, L. Discrimination of leukemias and non-leukemic cancers in blood serum samples of children and adolescents using a Raman spectral model. **Lasers in Medical Science**, [s. l.], v. 38, n. 1, p. 22, 2022.

LIU, X.; XU, W.; LI, L.; XU, X.; QI, H.; ZHANG, Z.; YANG, F.; YAN, Z.; LIU, C.; YUAN, R.; WAN, X.; SHU, R. Comparison on Quantitative Analysis of Olivine Using MarSCoDe Laser-Induced Breakdown Spectroscopy in a Simulated Martian Atmosphere. **Remote Sensing**, [s. l.], v. 14, n. 21, p. 5612, 2022.

LU, B.; DAO, P. D.; LIU, J.; HE, Y.; SHANG, J. Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture. **Remote Sensing**, [s. l.], v. 12, n. 16, p. 2659, 2020.

MAIRAJ, A.; BABA, A. I.; JAVAID, A. Y. Application specific drone simulators: Recent advances and challenges. **Simulation Modelling Practice and Theory**, [s. l.], v. 94, p. 100–117, 2019.

MOHSAN, S. A. H.; KHAN, M. A.; NOOR, F.; ULLAH, I.; ALSHARIF, M. H. Towards the Unmanned Aerial Vehicles (UAVs): A Comprehensive Review. **Drones**, [s. l.], v. 6, n. 6, p. 147, 2022.

MORENO, J. L.; ORTEGA, J. F.; MORENO, M. Á. Using an unmanned aerial vehicle (UAV) for lake management: ecological status, lake regime shift and stratification processes in a small Mediterranean karstic lake. [s. l.], 2022.

NEPOMUCENO, A. L.; FARIAS, J. R. B.; NEUMAIER, N. **Características da soja - Portal Embrapa soja**. 2021. 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: 26 jan. 2023.

OMIA, E.; BAE, H.; PARK, E.; KIM, M. S.; BAEK, I.; KABENGE, I.; CHO, B.-K. Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances. **Remote Sensing**, [s. l.], v. 15, n. 2, 2023.

**Organização das Nações Unidas para Agricultura e Alimentação | Terra e Água | Organização das Nações Unidas para Agricultura e Alimentação-Soja**. 2022. Disponível em: <<https://www.fao.org/land-water/databases-and-software/crop-information/soybean/es/>>. Acesso em: 26 jan. 2023.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and Electronics in Agriculture**, [s. l.], v. 153, p. 69–81, 2018.

PROCÓPIO, S.; JUNIOR, A.; DEBIASI, H.; FRANCHINI, J.; PANISON, F. Semeadura em fileira dupla e espaçamento reduzido na cultura da soja. [s. l.], v. 8, p. 212, 2014.

QUEIROZ, D. M.; VALENTE, D. S.; PINTO, F. de A. C.; BOREM, A. **Agricultura digital**. 2. ed. Lavras: Oficina de Textos, 2022.

RAIMUNDO, F.; GLORIA, A.; SEBASTIAO, P. Prediction of Weather Forecast for Smart Agriculture supported by Machine Learning. Em: 2021, **Anais...** . Em: 2021 IEEE WORLD AI IOT CONGRESS, AIOT 2021. [s.l: s.n.]

REDHU, N. S.; THAKUR, Z.; YASHVEER, S.; MOR, P. Artificial intelligence: a way forward for agricultural sciences. Em: **Bioinformatics in Agriculture: Next Generation Sequencing Era**. [s.l: s.n.]. p. 641–668.

REIS, L. K.; GUERRA, A.; COLADO, M. L. Z.; BORGES, F. L. G.; OLIVEIRA, M. da R.; GONDIM, E. X.; SINANI, T. R. F.; GUERIN, N.; GARCIA, L. C. Which spatial arrangement of green manure is able to reduce herbivory and invasion of exotic grasses in native species? **Ecological Applications**, [s. l.], v. 29, n. 8, p. e02000, 2019.

REJEB, A.; ABDOLLAHI, A.; REJEB, K.; TREIBLMAIER, H. Drones in agriculture: A review and bibliometric analysis. **Computers and Electronics in Agriculture**, [s. l.], v. 198, p. 107017, 2022.

RHYMA, P. P.; NORIZAH, K.; HAMDAN, O.; FARIDAH-HANUM, I.; ZULFA, A. W. Integration of normalised different vegetation index and Soil-Adjusted Vegetation Index for mangrove vegetation delineation. **Remote Sensing Applications: Society and Environment**, [s. l.], v. 17, p. 100280, 2020.

ROCHA, B. G. R.; AMARO, H. T. R.; PORTO, E. M. V.; GONÇALVES, C. C.; DAVID, A. M. S. S.; LOPES, E. B. Sistema de semeadura cruzada na cultura da soja: avanços e perspectivas. **Revista de Ciências Agrárias**, [s. l.], v. 41, n. 2, p. 376–384, 2018.

ROSAS, J. T. F.; DE CARVALHO PINTO, F. de A.; DE QUEIROZ, D. M.; DE MELO VILLAR, F. M.; MAGALHÃES VALENTE, D. S.; NOGUEIRA MARTINS, R. Coffee ripeness monitoring using a UAV-mounted low-cost multispectral camera. **Precision Agriculture**, [s. l.], v. 23, n. 1, p. 300–318, 2022.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. Em: 1974, **Anais...** [s.l: s.n.] Disponível em: <<https://ntrs.nasa.gov/citations/19740022614>>. Acesso em: 22 dez. 2022.

SAN EMETERIO DE LA PARTE, M.; MARTÍNEZ-ORTEGA, J.-F.; HERNÁNDEZ DÍAZ, V.; MARTÍNEZ, N. L. Big Data and precision agriculture: a novel spatio-temporal semantic IoT data management framework for improved interoperability. **Journal of Big Data**, [s. l.], v. 10, n. 1, 2023.

SANTOS-RUFO, A.; MESAS-CARRASCOSA, F.-J.; GARCÍA-FERRER, A.; MEROÑO-LARRIVA, J. E. Wavelength Selection Method Based on Partial Least Square from Hyperspectral Unmanned Aerial Vehicle Orthomosaic of Irrigated Olive Orchards. **Remote Sensing**, [s. l.], v. 12, n. 20, p. 3426, 2020.

SILVA, A. S.; SANTOS, A. S.; MIRANDA, A. C.; SOUSA, O. C. M. De; AGUIAR, C. D.; PROCHNOW, J. T.; MIELEZRSKI, F. Growth and production of soybean in response

to spatial arrangement in savannah climate. **Australian Journal of Crop Science**, [s. l.], n. 13(11):2019, p. 1901–1907, 2019.

SILVA, R. F. F. Da; DOBASHI, A. F. **Aprosoja/MS é uma entidade representativa de classe sem fins lucrativos, constituída por produtores rurais ligados às culturas de soja, milho e outros grãos de Mato Grosso do Sul**. [s.l: s.n.]. Disponível em: <<https://aprosojams.org.br/boletim-economico-aprosoja/36>>. Acesso em: 27 jan. 2023.

SILVA, M. de A.; SOARES, A. C. de S.; CARNIETTO, M. R. A.; BARBOSA, A. de M. Increasing population density reduces soybean yield components and productivity. **Bioscience Journal**, [s. l.], v. 37, p. e37042–e37042, 2021.

SISHODIA, R. P.; RAY, R. L.; SINGH, S. K. Applications of Remote Sensing in Precision Agriculture: A Review. **Remote Sensing**, [s. l.], v. 12, n. 19, p. 3136, 2020.

SOUZA, H. B.; BAIO, F. H. R.; NEVES, D. C. USING PASSIVE AND ACTIVE MULTISPECTRAL SENSORS ON THE CORRELATION WITH THE PHENOLOGICAL INDICES OF COTTON. **Engenharia Agrícola**, [s. l.], v. 37, p. 782–789, 2017.

SU, J.; ZHU, X.; LI, S.; CHEN, W.-H. AI meets UAVs: A survey on AI empowered UAV perception systems for precision agriculture. **Neurocomputing**, [s. l.], v. 518, p. 242–270, 2023.

TREVISAN, R.; PÉREZ, O.; SCHMITZ, N.; DIERS, B.; MARTIN, N. High-Throughput Phenotyping of Soybean Maturity Using Time Series UAV Imagery and Convolutional Neural Networks. **Remote Sensing**, [s. l.], v. 12, n. 21, p. 3617, 2020.

**USDA ERS**. 2022. Disponível em: <<https://www.ers.usda.gov/topics/crops/soybeans-and-oil-crops/>>. Acesso em: 24 jan. 2023.

VILLAR, F. M. de M.; ROSAS, J. T. F.; PINTO, F. de A. C. **Imagens e sensoriamento remoto aplicado a gestão agrícola**. 2. ed. Lavras: Oficina de Textos, 2022. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85035331085&doi=10.13031%2faim.201701511&partnerID=40&md5=b70863681e68af4e28b641a3ef73cbe4>>

WERNER, F.; BALBINOT JUNIOR, A.; FERREIRA, A.; SILVA, M.; MANDARINO, J.; ZUCARELI, C. Size, chlorophyll retention and protein and oil contents of grains from soybean plants grown in different spatial arrangements. **Semina: Ciências Agrárias**, [s. l.], v. 38, p. 85, 2017.

WERNER, F.; SILVA, M. A. de A. E; FERREIRA, A. S.; ZUCARELI, C.; JUNIOR, A. A. B. Grain, oil, and protein production on soybean stems and branches under reduced densities. **Revista Brasileira de Ciências Agrárias**, [s. l.], v. 16, n. 1, p. 1–9, 2021. a.



XIE, C.; YANG, C. A review on plant high-throughput phenotyping traits using UAV-based sensors. **Computers and Electronics in Agriculture**, [s. l.], v. 178, p. 105731, 2020.

YONG, K. J.; WU, T. Y. Second-generation bioenergy from oilseed crop residues: Recent technologies, techno-economic assessments and policies. **Energy Conversion and Management**, [s. l.], v. 267, p. 115869, 2022.

ZHANG, J.; CHEN, S.; WU, Z.; FU, Y. H. Review of vegetation phenology trends in China in a changing climate. **Progress in Physical Geography**, [s. l.], v. 46, n. 6, p. 829–845, 2022.

ZHOU, X. B.; CHEN, Y. H.; OUYANG, Z. Spacing between rows: effects on water-use efficiency of double-cropped wheat and soybean. **The Journal of Agricultural Science**, [s. l.], v. 153, n. 1, p. 90–101, 2015.

## **CAPÍTULO 2 - Resposta espectral: análise de componentes principais para a diferenciação de arranjos espaciais na soja**

### **2.1. Introdução**

A soja [*Glycine max* (L.) Merr.] é uma cultura de destaque econômico no Brasil, com produção de 125.55 milhões de toneladas na safra 2021/2022, mantendo o país como o maior produtor e exportador mundial da oleaginosa (CONAB, 2022; USDA, 2022). Trata-se de uma cultura de grande plasticidade morfológica, que apresenta capacidade de adaptação às diferentes condições ambientais e de manejo (LAMICHHANE et al., 2020). Entre as técnicas para o aumento da produtividade, a literatura descreve o espaçamento entre as linhas e a população de plantas como potencial estratégia (FERREIRA et al., 2018; SCHMITZ; STANLEY; KANDEL, 2020).

Os produtores buscam a evolução de suas fazendas com novas tecnologias e sistemas de gestão inteligente, além do proveito das cultivares (LIU et al., 2020; PATRÍCIO; RIEDER, 2018). Entretanto, há uma diversidade nas variedades de soja, com hábitos de crescimento diferentes que exigem mudanças no arranjo espacial. Ao mesmo tempo, a produtividade é um tópico crítico devido à sua dependência de fatores, como clima, genótipo e práticas de manejo (KHAKI; PHAM; WANG, 2021). Para contribuir para a gestão inteligente das fazendas, o monitoramento aéreo atrai cada vez mais atenção, como o uso de Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft* - RPA) com sensores de imagem de alta qualidade, que possibilitam a obtenção de dados da lavoura com resolução centimétrica e alta eficiência (QUEIROZ et al., 2022), permitindo a definição de estratégias desde a fenotipagem até o manejo (TREVISAN et al., 2020).

Dentre os produtos fornecidos via imagens de RPA, os índices de vegetação (IVs) se destacam por permitirem medir a resposta espectral da cobertura vegetal, podendo extrair diferentes variáveis como produtividade, uniformidade e comportamento fisiológico (SILVA et al., 2021). A identificação precisa e não destrutiva da lavoura ao longo do estágio de crescimento de uma cultura permite que os agricultores, empresas e agências governamentais tomem decisões para maximizar a produção agrícola. Isto é vital no manejo da cultura em termos de decisões específicas do local para maximizar o potencial de uma cultura e em última análise, para o benefício econômico de uma nação (KHAKI; PHAM; WANG, 2021).

As análises multivariadas como a análise de componentes principais (*Principal Component Analysis* - PCA) baseadas na transformação linear de um conjunto de variáveis, correlacionadas entre si, num conjunto menor de variáveis não correlacionadas, tem se tornado adequadas para diferenciar a resposta espectral da plantas, como a

maturação de frutos de café (ROSAS et al., 2022), genótipos de soja (LI et al., 2022) e cultivares de oliveira e cana-de-açúcar (AVOLA et al., 2019; BARBOSA JÚNIOR et al., 2022). No entanto a contagem de plantas na soja via imagens é um desafio devido ao elevado número de plantas por área, sobreposição de plantas e eventual perda de planta (RANDELOVIĆ et al., 2020). Além de que diferentes arranjos incluem condições de exposição de solo distintas ( espaçamento entre linhas), e sombreamentos. Dessa forma, uma estratégia é acompanhar as mudanças na resposta espectral da planta em diferentes datas após a emergência, tendo em vista que são moldadas de acordo com as variações nas características específicas da planta, incluindo índice de área foliar, teor de clorofila e reduções de biomassa (HUETE et al., 2002).

Estudos já evidenciaram que, apesar das mudanças morfofisiológicas, as cultivares atualmente utilizadas apresentam alta plasticidade; portanto, a produtividade por área varia pouco com alterações significativas na população de plantas e no espaçamento entre linhas (JUNIOR et al., 2015; PETTER et al., 2016). Sendo a redução da população de sementeira, uma estratégia de redução de custo (WERNER et al., 2021b). No entanto, cada cultivar tem suas recomendações de arranjo espacial, tendo em vista principalmente a recomendação de quantidade de sementes por hectare, que da sementeira à colheita, a soja pode passar por estresses de natureza biótica e abiótica na qual reflete no estado final de plantas além de diferentes requisitos de insumos (fertilizantes, inseticidas, herbicidas etc.) e manejos. Portanto, ser capaz de identificar os arranjos esse tipo de trabalho a nível local permitiria ao agricultor utilizar o manejo inteligente dos insumos, e em maiores proporções viabilizaria aos órgãos governamentais a informação de qual arranjo os produtores utilizaram, e assim direcionar estimativas de produção à nível nacional utilizando satélite. assim, estimar a produtividade de acordo com o arranjo.

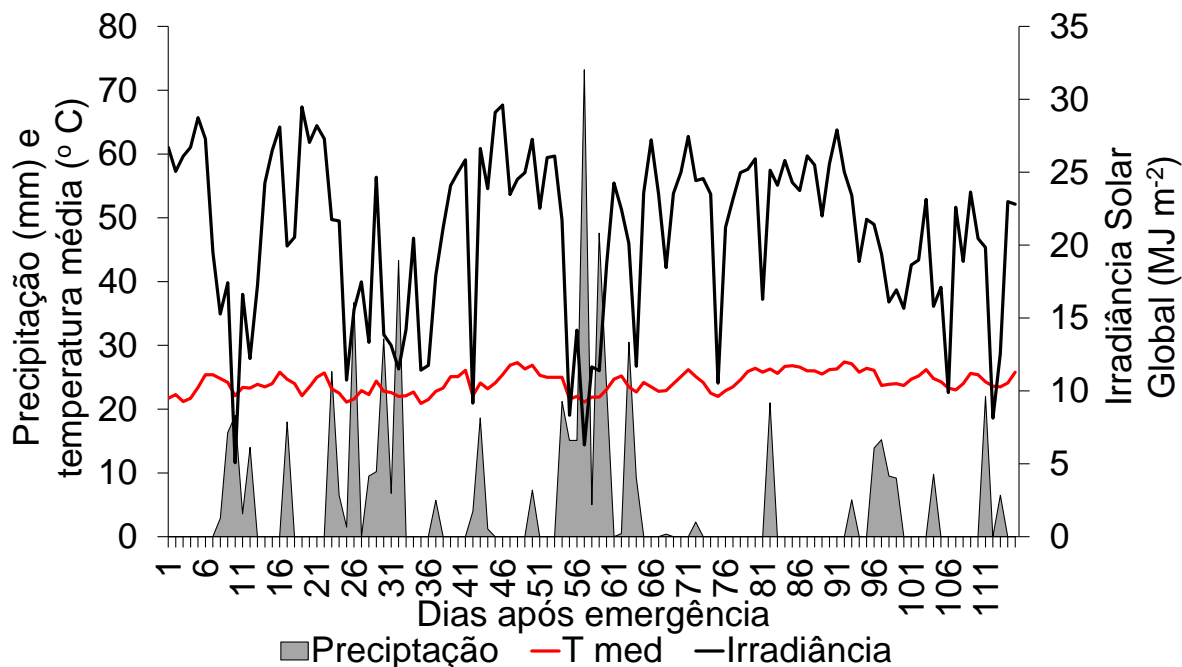
A hipótese do trabalho é que a resposta espectral da soja captada pelo sensor multiespectral embarcado em RPA pode ser utilizada para caracterizar os arranjos espaciais, tendo em vista que alterando o espaçamento entre linhas e a população, a resposta espectral também sofreria alteração, sendo passível de ser diferenciado com a aplicação bandas espectrais e índices de vegetação em análise de componentes principais. Dessa forma o objetivo deste estudo foi diferenciar os arranjos espaciais de soja a partir de resposta espectral da cultura e da análise de componentes principais.

## **2.2. Material e Métodos**

### **2.2.1. Área de estudo**

O experimento foi conduzido em área experimental da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, São Paulo, Brasil (21°14'31" S, 48°17'24" W) na safra

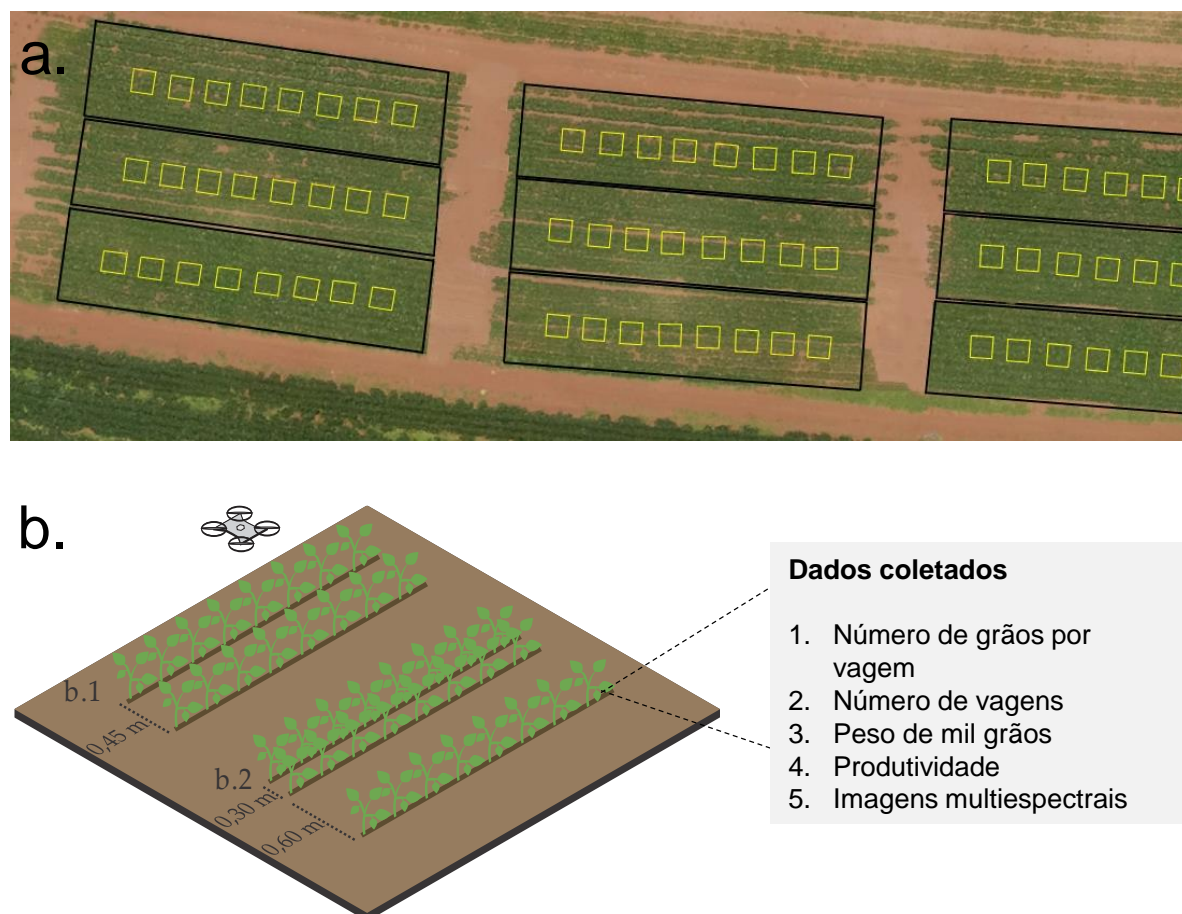
2021/22. O clima é Cwa, subtropical de inverno, relativamente seco (ALVARES et al., 2013). A temperatura média anual é 22°C e a pluviosidade média anual de 1424 mm. O tipo de solo do local de estudo é Latossolo vermelho Distrófico, com textura argilosa típica (SANTOS et al., 1974).



**Figura 1.** Dados climáticos diários: precipitação (mm), temperatura média (°C) e irradiância solar global (MJ m<sup>-2</sup>) ocorridas no período da safra de dezembro 2021 a março 2022 de acordo com os dias após a emergência (DAE).

### 2.2.2. Delineamento experimental, Condução do experimento e avaliação de estande

Foram utilizados dois espaçamentos de semeadura: convencional (C) com 0,45 m e linhas duplas intercaladas (D) com duas linhas de 0,30 m por uma de 0,60 m. Além disso, três populações de plantas: P1= 300, P2= 350 e P3= 400 mil plantas ha<sup>-1</sup>. Portanto, compondo um fatorial 2 x 3 com 4 repetições que totalizou 24 parcelas experimentais de 20 x 5 m (100 m<sup>2</sup>). Para a coleta dos pontos de produtividade foram selecionadas 3 linhas centrais de cada parcela, com 8 pontos coletados em área amostral de 1 m<sup>2</sup>, que resultando em 192 pontos de produtividade ( Figura 2).



**Figura 2. a.** Vista superior da área experimental, em que retângulos pretos representam as parcelas e quadrículas amarelas as amostras; **b.** espaçamento entre linhas da cultura, em que **b.1** espaçamento convencional de 0,45 m (C) e **b.2** espaçamento duplo intercalado de 0,30 m-0,60 m (D).

A semeadura foi realizada com a semeadora adubadora Jumil 2640 PD de 5 linhas em preparo de solo convencional. O trator utilizado para tracionar a semeadora adubadora foi da marca Massey Ferguson, modelo MF-620, 4x2 TDA com 72,3 kW (105 cv) de potência no motor. A cultivar de soja semeada foi a 96Y90 da Pioneer® precoce com hábito de crescimento indeterminado e boa tolerância ao acamamento. Seu ciclo médio é em torno de 115 a 125 dias. O estande de plantas foi avaliado em todas as parcelas aos 25 DAE. A contagem de plantas ocorreu em três linhas de semeadura de 6,0 m.

### 2.2.3. Aquisição de Dados Espectrais no Campo com RPA e Processamento de Imagem

Foram realizados seis voos aos 45, 55, 65,75, 85 e 95 DAE, correspondendo as datas 23/01/22, 03/02/22, 14/02/22, 24/02/22, 06/03/22 e 16/03/22 e aos ciclos fenológicos V6, R2, R4, R5, R6 e R7, respectivamente. A aquisição das imagens multiespectrais foi realizada com a câmera multiespectral do equipamento DJI Phantom 4 Multispectral (P4M) (SZ DJI Technology Co., Ltd., Shenzhen, China). A câmera possui

seis sensores CMOS de 1/2,9" montados, incluindo um sensor RGB e cinco sensores monocromáticos para medir a resposta espectral nas bandas azul, verde, vermelho, borda do vermelho e infravermelho próximo (Tabela 1). Cada sensor fornece resolução de imagem de 1600 × 1300 pixels. A câmera também é equipada com um sensor de irradiância, integrado na parte superior, que permite a compensação da luminância e a eliminação do ruído ambiental dos dados brutos para o processamento das imagens. Os voos foram realizados ao meio-dia ( $\pm 1h$ ) com um controle para o plano de voo (DJI GS PRO, Shenzhen, China), desde a decolagem até o pouso. Foi utilizado um receptor GNSS-RTK, garantindo precisão posicional centimétrica e aquisição de dados temporais do mesmo ponto. Os parâmetros de voo foram: sobreposição frontal de 75% e lateral de 70%, com altura de voo de 60 m, e resolução espacial de aproximadamente 3,5 cm.

**Tabela 1.** Comprimento de onda para bandas presentes no sensor do P4M.

Banda	Comprimento de onda (nm)	Largura de banda FWHM (nm)
Azul	450	16
Verde	560	16
Vermelho	650	16
Borda do vermelho	730	16
Infravermelho próximo	840	26

As imagens foram processadas no software Agisoft Metashape (São Petesburgo, Rússia) para produzir os ortomosaicos. Os dados das bandas espectrais e IVs (Tabela 2) foram extraídos das parcelas amostrais do campo de estudo. Para esta etapa foi utilizada a ferramenta de máscara e estatística zonal do software QGIS 3.22.6 (Boston, MA, EUA). Os Ivs foram selecionados por serem usuais em estudos com a resposta espectral da vegetação (DOS SANTOS et al., 2021; SANTANA et al., 2023; WALDREP et al., 2022).

**Tabela 2.** Índices de vegetação utilizados

Índice de Vegetação	Equação	Referência
Índice de vegetação por diferença normalizada (NDVI)	$\frac{NIR - Red}{NIR + Red}$	(ROUSE et al., 1974)
Índice de vegetação ajustado ao solo (SAVI)	$\left( \frac{NIR - Red}{NIR + Red + L} \right) (1 + L)$	(HUETE, 1988)
Índice de vegetação não linear (NLI)	$\left( \frac{NIR^2 - Red}{NIR^2 + Red} \right)$	(GOEL; QIN, 1994)

NIR: infravermelho próximo; Red: vermelho; Green.

## 2.2.4. Avaliação de produtividade

A colheita foi realizada de forma manual aos 115 DAE, com auxílio de uma armação com área de 1 m<sup>2</sup> nos 192 pontos distribuídos nas 24 parcelas. Dez plantas de quatro pontos de produtividade de cada tratamento foram selecionadas para avaliação do número de vagens por planta (NVP), número de grãos por vagens (NV) e massa de mil de grãos (MMG) corrigida para 13% de umidade. Posteriormente foram devolvidas para amostra original e trilhadas na colhedora de parcela Wintersteiger modelo A-4910. Os grãos foram separados, pesados e os valores corrigidos para a base úmida de 13%, os foram valores extrapolados para kg.ha<sup>-1</sup>.

## 2.2.5. Análise de dados

Foi realizada a análise de variância para produtividade, NVP, NV e MMG para verificar a interação entre os tratamentos. Para cada variável analisada, as médias dos tratamentos foram comparadas por meio dos testes F e Tukey a 5% de probabilidade. Para o conjunto de bandas espectrais e índices de vegetação foi aplicada a técnica estatística multivariada de análise de componentes principais (PCA). Desse modo, é possível extrair informações dos dados espectrais e transformar os dados em um conjunto de variáveis ortogonais não correlacionadas chamadas de componentes principais (PCs). Assim, consegue-se explorar a possibilidade de diferenciar arranjos espaciais na soja por meio da resposta espectral. Para a interpretação dos componentes foram selecionados os PCs com autovetores com correlação forte significativa ( $r \Rightarrow 0,8$ ; valor  $p < 0,05$ ). As análises foram realizadas na linguagem de programação R.

## 2.3. Resultados e Discussão

### 2.3.1. Variáveis produtivas

Houve interação fatorial significativa apenas para produtividade, que foi afetada pela população de plantas (Tabela 3). Silva et al., (2021) analisando três espaçamentos entre linhas e três populações de plantas obteve o mesmo comportamento para a interação dos fatores, onde houve um maior efeito do aumento da densidade populacional, do que dos espaçamentos adotados entre as linhas.

**Tabela 3.** Valores médios obtidos para o desdobramento da produtividade (kg.ha) em arranjos espaciais na soja.

Espaçamento / População de plantas	Produtividade (kg.ha <sup>-1</sup> )		
	P1	P2	P3

Convencional	2.55 Bc	2.79 Ab	3.21 Aa	*
Linha dupla	2.82 Aa	2.79 Aa	2.99 Ba	
Teste F EL		0.12 NS		
Teste F P		22.88**		
Teste F EL x P		7.25**		
CV%		12.76		

Médias seguidas de letras distintas diferem entre si, na coluna maiúscula e minúscula na linha pelo teste de Tukey a 5% de probabilidade; CV- Coeficiente de Variação; EL – Espaçamento entre linhas; P- População de plantas; P1- 300.000, P2- 350.000 e P3- 400.000 plantas.ha<sup>-1</sup>.

Na P1 a linha dupla teve a maior produtividade, na P2 os espaçamentos de semeadura foram igualmente responsivos, para a P3 o espaçamento convencional teve a maior produtividade. No espaçamento convencional a P3 teve as maiores médias de produtividade, enquanto não houve diferença significativa entre população de plantas na linha dupla.

A maior produtividade nas maiores populações P2 e P3 e espaçamento convencional corrobora com o encontrado por Ferreira et al., (2016) com produtividade da soja em função das populações de plantas (135, 235, 315 e 440 mil plantas ha<sup>-1</sup>), onde a máxima eficiência técnica foi obtida com aproximadamente 350 mil plantas ha<sup>-1</sup>. Kuss et al., (2008) também relataram maior produtividade na população de 400 mil plantas ha<sup>-1</sup> e diminuição na produtividade quando a população de plantas foi reduzida de 400 mil para 250 mil plantas ha<sup>-1</sup>.

Para o número de vagens por planta e número de grãos por vagem (Tabela 4), verificou-se que o CP3 obteve média superior a todos os demais tratamentos, exceto para o número de grãos por vagem que continham apenas um grão. O desempenho superior do CP3 para o número de vagens por planta e número de grão por vagem, não é comum na literatura dos últimos cinco anos, no qual a produção de grãos aumentou com a diminuição da população de plantas (ANDRADE et al., 2016; SILVA et al., 2021; WERNER et al., 2021b). Tal fato pode ter ocorrido na maior população devido a maior competição estimular o crescimento das raízes no perfil do solo a procura de água, resultando em maior produtividade (ALVES et al., 2021; PIMENTEL; BAYÃO; LELIS, 2016).



**Tabela 4.** Valores médios de número de vagens por planta (NVP), número de grãos por vagem (NV), e massa de 1000 grãos (MMG) para arranjos espaciais da soja.

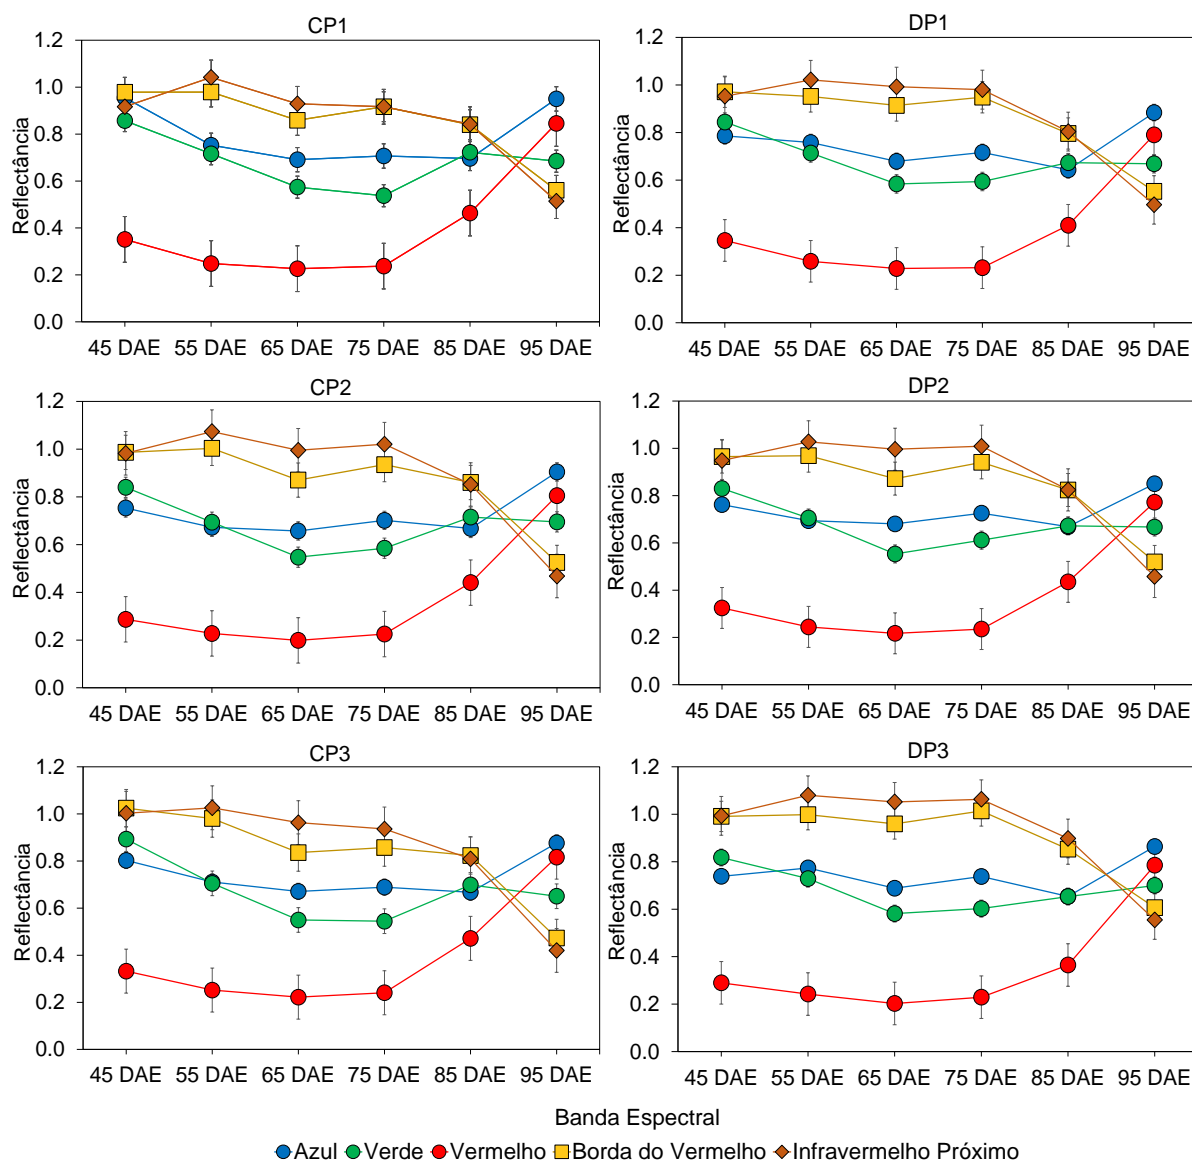
Tratamentos	NVP	NV				MMG (g)
		1	2	3	4	
CP1	58.9 b	11.9 a	23.6 b	22.7 bc	0.6 ab	150.08 a
CP2	40.1 bc	8.3 a	16.0 b	15.3 c	0.3 bc	140.84 a
CP3	82.1 a	8.3 a	38.0 a	34.9 a	0.8 a	130.55 bc
DP1	47.4 bc	10.7 a	16.9 b	19.5 bc	0.15 c	140.73 a
DP2	54.0 bc	9.4 a	22.2 b	22.0 bc	0.4 bc	130.95 b
DP3	53.1 b	9.3 a	19.9 b	23.6 b	0.3 c	130.09 c
CV(%)	9.34	17.7	16.2	14.8	27.0	6.56

C- Espaçamento Convencional entre linhas, D- Espaçamento em linhas duplas; P1- 300.000, P2- 350.000 e P3-400.000 plantas ha<sup>-1</sup>. CV- Coeficiente de Variação. Médias seguidas por letras distintas diferem entre si pelo teste de Tukey a 5%.

Para massa de mil grãos, as melhores médias foram encontradas para as menores populações de plantas CP1, CP2 e DP1, seguidas pelo CP2 e CP3 com médias intermediárias, enquanto as menores médias foram para DP3, que não diferiu da CP3. Este resultado pode ser explicado pelos dias sem chuva na fase de enchimento de grãos, aos 75 DAE (Figura 1). Tal condição pode ter aumentado a competição interespecífica por água nas maiores populações, o que resultou em menor peso de mil grãos e, portanto, melhores condições poderiam ter o aumento na produção de grãos por planta. Nesse momento pode ter ocorrido a compensação nas menores populações de plantas por terem menos vagens (Tabela 4) por ter menor competição. Balbinot Junior *et al.*, (2018) relataram que a redução da população de semeadura aumentou o número de grãos por planta devido ao aumento da porcentagem de grãos dos ramos que são menos exigentes por fotoassimilados em relação aos colmos.

### 2.3.2. Resposta espectral na diferenciação dos arranjos

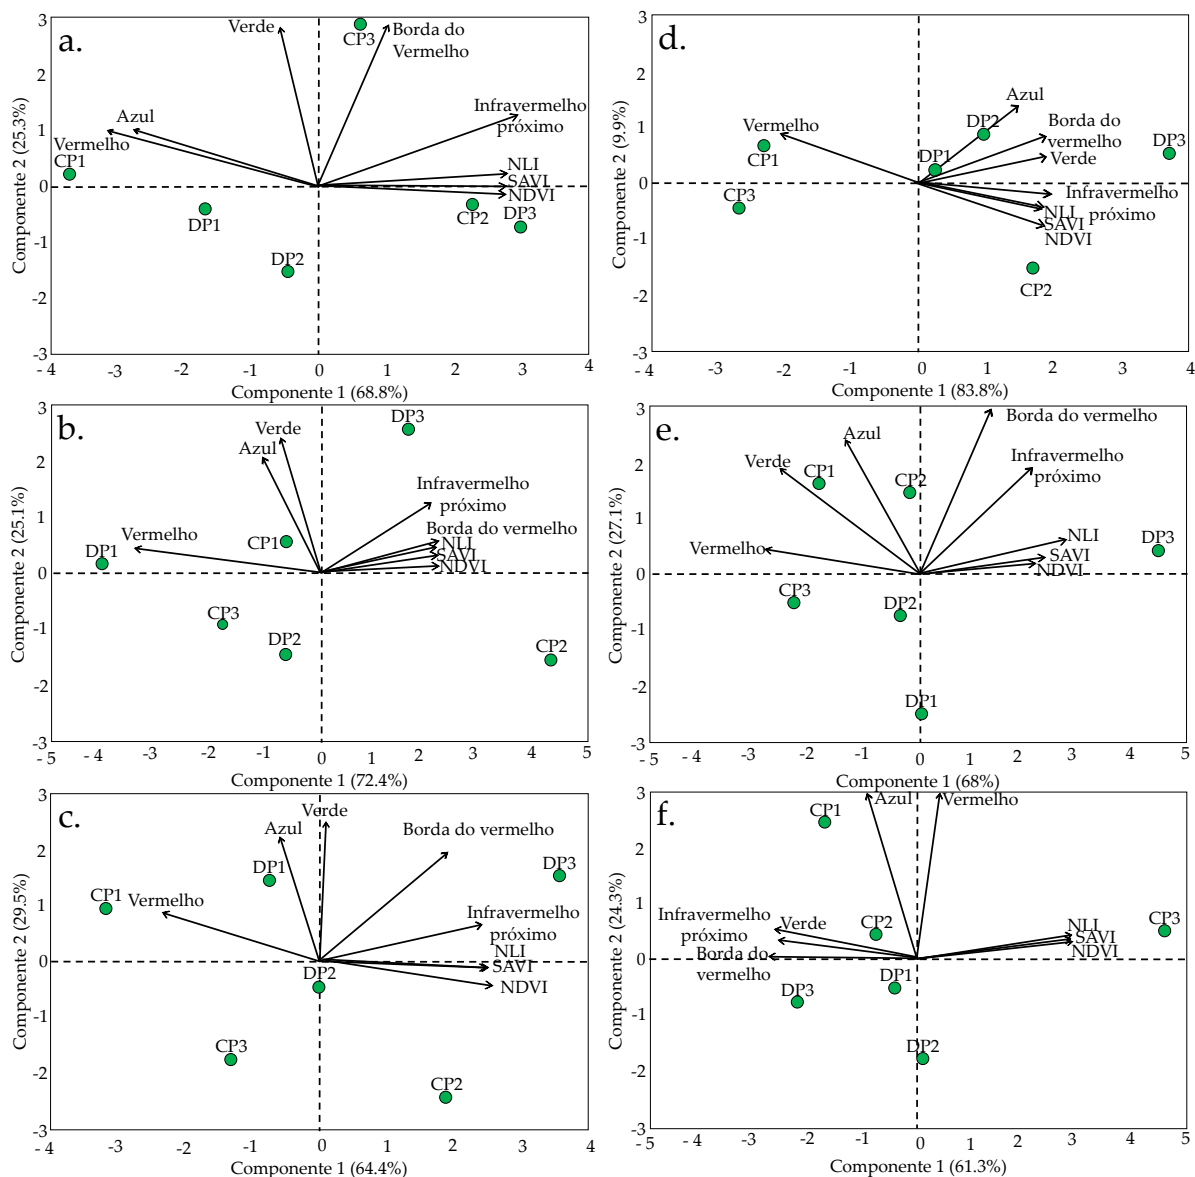
A refletância da soja (Figura 3), expressou a variabilidade temporal para os arranjos espaciais. Para os arranjos é possível observar que o comportamento espectral foi bem semelhante. As datas dos voos mostram como o estágio fenológico impactou a refletância, especialmente para comprimentos de onda mais longos.



**Figura 3.** Média e desvio padrão do comportamento espectral dos arranjos espaciais de soja em função dos dias após emergência (DAE).

A banda do vermelho forneceu a maior variação na reflectância. Em contraste, a banda do azul forneceu a menor variação na reflectância. A banda do infravermelho próximo teve o pico aos 55 DAE e foi decrescendo aos 85 DAE, enquanto a banda do vermelho teve comportamento oposto. Geralmente, a banda do vermelho e do infravermelho próximo são mais responsivas para a discriminação da vegetação (BARBOSA JÚNIOR et al., 2022), onde a fotossíntese está relacionada com a quantidade de radiação absorvida no espectro visível (bandas do vermelho e do azul), e folhas senescentes refletem mais fortemente no espectro visível do que folhas jovens com relação inversa para o infravermelho próximo (MORLIN CARNEIRO et al., 2020). A banda do vermelho apresentou uma resposta espectral acentuada aos 45 DAE no estágio vegetativo V6, ao longo da floração e enchimento de grãos a resposta diminuiu e na maturação voltou a aumentar. A reflectância no infravermelho próximo apresentou decréscimo acentuado aos 85 e 95 DAE quando a soja se encontrava em R6 e R7. Tais

resultados mostraram que o sensor multiespectral possibilitou que as bandas acompanhassem a variação da resposta da cultura ao longo do tempo, pois a capacidade das folhas em realizar a fotossíntese aumentou desde o estágio vegetativo até o reprodutivo, enquanto a taxa fotossintética reduziu significativamente até a completa maturação da planta (MORLIN CARNEIRO et al., 2020).



**Figura 4.** Análise de componentes principais para arranjos espaciais em bandas espectrais e índices de vegetação de acordo com a data de avaliação. **a.** 45 DAE; **b.** 55 DAE; **c.** 65 DAE; **d.** 75 DAE; **e.** 85 DAE; **f.** 95 DAE.

A PCA resumiu adequadamente os dados de imagens de alta resolução dos arranjos espaciais nas diferentes datas de voo (Figura 4) com comportamento espectral com poucas sobreposições. O componente 1 e o componente 2, juntos explicaram acima de 85% dos dados, o que está acima do limite crítico de 80% para PCA (JOLLIFFE; CADIMA, 2016), explicando a variação nos arranjos (Tabela 1, Apêndice).

A PCA também evidenciou a influência temporal na disposição e estruturação de autovalores e autovetores de acordo com os estágios fenológicos. Para o componente 1

as bandas do vermelho e infravermelho próximo tiveram correlação negativa e positiva significativa respectivamente uma com outra (inversamente correlacionado), dos 45 DAE aos 75 DAE. Nessas datas os estágios fenológicos foram de V6 a R5. A banda do vermelho continuou com correlação forte negativa aos 85 DAE, porém próximo da colheita aos 95 DAE, no R7 as correlações fortes negativas foram para a banda do verde, borda do vermelho e infravermelho próximo. A banda do vermelho contribuiu mais efetivamente para a caracterização do arranjo espacial CP1. O infravermelho próximo contribuiu mais efetivamente para a caracterização do arranjo espacial DP3. Os tratamentos CP2, CP3, DP1 e DP2 moveram-se em direção aos quadrantes que consistem em baixas cargas com bandas espectrais, independentemente da data de avaliação. Na componente 2 a banda do verde obteve correlação forte positiva nas 3 primeiras datas avaliadas, que contribuiu para explicar o CP3 e DP3.

Os IVs tiveram uma contribuição forte e positiva para a componente 1, no qual o comportamento de refletância obteve sobreposições. Qualquer índice poderia explicar a variância e a maior contribuição foi para a caracterização da DP3 nas 5 primeiras datas. Aos 95 DAE os IVs contribuíram para explicar a variância da CP3.

Bandas espectrais e IVs provaram ser diferenciadores dos arranjos. Porém, a redundância existente no mapa fatorial pode dificultar a interpretação do resultado. Para o componente 1 as bandas e IVs contribuíram mais efetivamente para a caracterização do arranjo espacial DP3 e CP3 (Figura 4) respectivamente. Portanto, o componente 1 pode ser atribuído à população de plantas, enquanto o componente 2 é caracterizado e interpretado como o espaçamento entre linhas. Para uma melhor diferenciação poder-se-ia testar um número maior de população de plantas por ter sido o fator com interação fatorial significativa para produtividade (Tabela 3).

A cultivar estudada é de hábito de crescimento indeterminado, ou seja, que continua seu crescimento vegetativo e produzem nós no caule principal até o início do enchimento de grão, apresentando baixa ramificação e crescimento vegetativo. As cultivares com hábito de crescimento determinado interrompem o crescimento vegetativo e produzem nós antes do florescimento, com alto grau de ramificação e forte crescimento vegetativo (PROCÓPIO et al., 2014; WERNER et al., 2021b). Logo seria interessante testar arranjos com os dois hábitos de crescimento diferentes. França et al., (2021) trabalhando com cultivares e populações de soja verificaram que as características agrônomicas e suas sementes variam de acordo com os genótipos e que essas expressões fenotípicas podem alterar de acordo com a população de plantas.

Considerando a plasticidade fenotípica da cultura, uma possibilidade a ser explorada é o acompanhamento de variáveis com número de ramos, diâmetro do caule e

área foliar conjuntamente com os voos para avaliar se é possível diferenciar arranjos espaciais via sensoriamento remoto com inserção de novas variáveis.

#### 2.4. Conclusões

O sensor multiespectral da aeronave remotamente pilotada tem potencial para a diferenciação de arranjos espaciais na soja.

A banda do vermelho e do infravermelho próximo foram as mais responsivas para diferenciação dos arranjos dos 45 aos 75 dias após a emergência.

Independentemente da data, NDVI, SAVI e NLI apresentaram mesma capacidade de diferenciar os arranjos. Novas cultivares e variáveis devem ser adicionadas durante as datas. Elas fornecerão mais conhecimento sobre a diferenciação de arranjos com dados de imagens multiespectrais coletadas por RPAS.

#### Referências

AVOLA, G.; DI GENNARO, S. F.; CANTINI, C.; RIGGI, E.; MURATORE, F.; TORNAMBÈ, C.; MATESE, A. Remotely Sensed Vegetation Indices to Discriminate Field-Grown Olive Cultivars. *Remote Sensing*, [s. l.], v. 11, n. 10, p. 1242, 2019.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, [s. l.], v. 22, n. 6, p. 711–728, 2013.

ALVES, C. P.; JÚNIOR, B. C.; ROCHA, A. K. P.; VIEIRA, D. S. M. de M.; EUGÊNIO, D. da S.; LEITE, M. L. de M. V. Respostas morfofisiológicas das plantas forrageiras sob manejo de cultivo e pastejo: Uma revisão. **Research, Society and Development**, [s. l.], v. 10, n. 6, p. e10610615405–e10610615405, 2021.

ANDRADE, F.; NÓBREGA, J.; ZUFFO, A.; JUNIOR, V.; RAMBO, T.; SANTOS, A. Características Agronômicas e produtivas da soja cultivada em plantio convencional e cruzado. **Revista de Agricultura (Piracicaba)**, [s. l.], v. 91, p. 81–91, 2016.

BALBINOT JUNIOR, A. A.; OLIVEIRA, M. C. N. De; FRANCHINI, J. C.; DEBIASI, H.; ZUCARELI, C.; FERREIRA, A. S.; WERNER, F. Phenotypic plasticity in a soybean cultivar with indeterminate growth type. **Pesquisa Agropecuária Brasileira**, [s. l.], v. 53, p. 1038–1044, 2018.

BARBOSA JÚNIOR, M. R.; TEDESCO, D.; CARREIRA, V. dos S.; PINTO, A. A.; MOREIRA, B. R. de A.; SHIRATSUCHI, L. S.; ZERBATO, C.; SILVA, R. P. Da. The Time of Day Is Key to Discriminate Cultivars of Sugarcane upon Imagery Data from Unmanned Aerial Vehicle. **Drones**, [s. l.], v. 6, n. 5, p. 112, 2022.

**CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. Safra Brasileira de Grãos, Decimo segundo Levantamento - Safra 2021/22.** 12. ed. [s.l.] : Superintendência de Marketing e Comunicação (Sumac) Gerência de Eventos e Promoção Institucional (Gepin), 2022. v. 9 Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos>>

DOS SANTOS, A. F.; CORRÊA, L. N.; LACERDA, L. N.; TEDESCO-OLIVEIRA, D.; PILON, C.; VELLIDIS, G.; DA SILVA, R. P. High-resolution satellite image to predict peanut maturity variability in commercial fields. **Precision Agriculture**, [s. l.], v. 22, n. 5, p. 1464–1478, 2021.

FERREIRA, A. S.; BALBINOT JUNIOR, A. A.; WERNER, F.; FRANCHINI, J. C.; ZUCARELI, C. Soybean agronomic performance in response to seeding rate and phosphate and potassium fertilization. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [s. l.], v. 22, p. 151–157, 2018.

FERREIRA, A. S.; BALBINOT JUNIOR, A. A.; WERNER, F.; ZUCARELI, C.; FRANCHINI, J. C.; DEBIASI, H. Plant density and mineral nitrogen fertilization influencing yield, yield components and concentration of oil and protein in soybean grains. **Bragantia**, [s. l.], v. 75, p. 362–370, 2016.

FRANÇA, E. E.; SILVA, G. C. Da; VIANA DE ARAÚJO, M. E.; TEIXEIRA, I. R.; CORRÊA, P. C.; GUERRA DA SILVA, A.; FRANÇA, E. E.; SILVA, G. C. Da; VIANA DE ARAÚJO, M. E.; TEIXEIRA, I. R.; CORRÊA, P. C.; GUERRA DA SILVA, A. Agronomic and physiological characteristics of soybean cultivars and their seeds according to plant population. **Agronomía Colombiana**, [s. l.], v. 39, n. 2, p. 177–186, 2021.

GOEL, N. S.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and Fpar: A computer simulation. **Remote Sensing Reviews**, [s. l.], v. 10, n. 4, p. 309–347, 1994.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, [s. l.], v. 25, n. 3, p. 295–309, 1988.

JUNIOR, A. A. B.; PROCÓPIO, S. de O.; DEBIASI, H.; FRANCHINI, J. C.; PANISON, F. Semeadura cruzada em cultivares de soja com tipo de crescimento determinado. **Semina: Ciências Agrárias**, [s. l.], v. 36, n. 3, p. 1215–1226, 2015.

JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, [s. l.], v. 374, n. 2065, p. 20150202, 2016.

KHAKI, S.; PHAM, H.; WANG, L. Simultaneous corn and soybean yield prediction from remote sensing data using deep transfer learning. **Scientific Reports**, [s. l.], v. 11, n. 1, p. 11132, 2021.

KUSS, R. C. R.; KÖNIG, O.; DUTRA, L. M. C.; BELLÉ, R. A.; ROGGIA, S.; STURMER, G. R. Populações de plantas e estratégias de manejo de irrigação na cultura da soja. **Ciência Rural**, [s. l.], v. 38, p. 1133–1137, 2008.

LAMICHHANE, J. R.; CONSTANTIN, J.; SCHOVING, C.; MAURY, P.; DEBAEKE, P.; AUBERTOT, J.-N.; DÜRR, C. Analysis of soybean germination, emergence, and prediction of a possible northward establishment of the crop under climate change. **European Journal of Agronomy**, [s. l.], v. 113, p. 125972, 2020.

LI, D.; BAI, D.; TIAN, Y.; LI, Y.-H.; ZHAO, C.; WANG, Q.; GUO, S.; GU, Y.; LUAN, X.; WANG, R.; YANG, J.; HAWKESFORD, M. J.; SCHNABLE, J. C.; JIN, X.; QIU, L.-J. Time series canopy phenotyping enables the identification of genetic variants controlling dynamic phenotypes in soybean. **Journal of Integrative Plant Biology**, [s. l.], v. n/a, n. n/a, 2022. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/jipb.13380>>. Acesso em: 24 jan. 2023.

LIU, S.; ZHANG, M.; FENG, F.; TIAN, Z. Toward a “Green Revolution” for Soybean. **Molecular Plant**, [s. l.], v. 13, n. 5, p. 688–697, 2020.

MORLIN CARNEIRO, F.; ANGELI FURLANI, C. E.; ZERBATO, C.; CANDIDA DE MENEZES, P.; DA SILVA GÍRIO, L. A.; FREIRE DE OLIVEIRA, M. Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. **Precision Agriculture**, [s. l.], v. 21, n. 5, p. 979–1007, 2020.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and Electronics in Agriculture**, [s. l.], v. 153, p. 69–81, 2018.

PETTER, F. A.; SILVA, J. A. Da; ZUFFO, A. M.; ANDRADE, F. R.; PACHECO, L. P.; ALMEIDA, F. A. De. Elevada densidade de semeadura aumenta a produtividade da soja? Respostas da radiação fotossinteticamente ativa. **Bragantia**, [s. l.], v. 75, p. 173–183, 2016.

PIMENTEL, R. M.; BAYÃO, G. F. V.; LELIS, D. L. Ecofisiologia de plantas forrageiras. [s. l.], 2016.

PROCÓPIO, S.; JUNIOR, A.; DEBIASI, H.; FRANCHINI, J.; PANISON, F. Semeadura em fileira dupla e espaçamento reduzido na cultura da soja. [s. l.], v. 8, p. 212, 2014.

QUEIROZ, D. M.; VALENTE, D. S.; PINTO, F. de A. C.; BOREM, A. **Agricultura digital**. 2. ed. Lavras: Oficina de Textos, 2022.

RANDELOVIĆ, P.; ĐORDEVIĆ, V.; MILIĆ, S.; BALE EVIĆ-TUBIĆ, S.; PETROVIĆ, K.; MILADINOVIĆ, J.; ĐUKIĆ, V. Prediction of soybean plant density using a machine learning model and vegetation indices extracted from RGB images taken with a UAV. **Agronomy**, [s. l.], v. 10, n. 8, 2020.

ROSAS, J. T. F.; DE CARVALHO PINTO, F. de A.; DE QUEIROZ, D. M.; DE MELO VILLAR, F. M.; MAGALHÃES VALENTE, D. S.; NOGUEIRA MARTINS, R. Coffee ripeness monitoring using a UAV-mounted low-cost multispectral camera. **Precision Agriculture**, [s. l.], v. 23, n. 1, p. 300–318, 2022.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. Em: 1974, **Anais...** [s.l: s.n.] Disponível em: <<https://ntrs.nasa.gov/citations/19740022614>>. Acesso em: 22 dez. 2022.

SANTANA, D. C.; TEODORO, L. P. R.; BAIO, F. H. R.; SANTOS, R. G. D.; CORADI, P. C.; BIDUSKI, B.; SILVA JUNIOR, C. A. D.; TEODORO, P. E.; SHIRATSUCHI, L. S. Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. **Remote Sensing Applications: Society and Environment**, [s. l.], v. 29, 2023.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAUJO, F., J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. Brasília, DF: Embrapa, 8570358172.

SCHMITZ, P. K.; STANLEY, J. D.; KANDEL, H. Row spacing and seeding rate effect on soybean seed yield in North Dakota. **Crop, Forage & Turfgrass Management**, [s. l.], v. 6, n. 1, p. e20010, 2020.

SILVA, M. de A.; SOARES, A. C. de S.; CARNIETTO, M. R. A.; BARBOSA, A. de M. Increasing population density reduces soybean yield components and productivity. **Bioscience Journal**, [s. l.], v. 37, p. e37042–e37042, 2021.

TREVISAN, R.; PÉREZ, O.; SCHMITZ, N.; DIERS, B.; MARTIN, N. High-Throughput Phenotyping of Soybean Maturity Using Time Series UAV Imagery and Convolutional Neural Networks. **Remote Sensing**, [s. l.], v. 12, n. 21, p. 3617, 2020.

**USDA ERS**. 2022. Disponível em: <<https://www.ers.usda.gov/topics/crops/soybeans-and-oil-crops/>>. Acesso em: 24 jan. 2023.



WALDREP, K. S.; TAGERT, M. L. M.; MCCOY, J.; HARRISON, M.; TAYLOR, A. UAV Multispectral Imagery for Site-Specific Management of Iron Deficiency Chlorosis (IDC) in Soybean. Em: 2022, **Anais...** . Em: 2022 ASABE ANNUAL INTERNATIONAL MEETING. [s.l: s.n.] Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85137605668&doi=10.13031%2faim.202201111&partnerID=40&md5=b6b1e218bff4d769ca2be7573b5f36c1>>

WERNER, F.; SILVA, M. A. de A. E.; FERREIRA, A. S.; ZUCARELI, C.; JUNIOR, A. A. B. Grain, oil, and protein production on soybean stems and branches under reduced densities. **Revista Brasileira de Ciências Agrárias**, [s. l.], v. 16, n. 1, p. 1–9, 2021.

## Apêndice

Tabela1. Análise de componentes principais (Parte I)

COLEÇÃO I- 45 DAE	Componentes Principais	
	PCI	PCII
Autovalor	4.59 *	1.68 *
Porcentagem de variância	68.78	25.25
Porcentagem cumulativa de variância	68.78	94.03
Autovetor	Coeficiente de Correlação	
b1	-0.82 **	0.25
b2	-0.29	0.93 **
b3	-0.93 **	0.26
b4	0.39	0.91**
b5	0.87**	0.44
NDVI	0.99 **	-0.05
SAVI	1 **	-0.01
NLI	1 **	-0.03
Autovalor	Coeficiente de Correlação	
Cp1	44.29	0.10
Cp2	19.27	1.25
Cp3	1.23	74.74
Dp1	8.57	2.48
Dp2	0.97	16.59
Dp3	25.68	4.84
COLEÇÃO II 55 DAE	Componentes Principais	
	PCI	PCII
Autovalor	4.83*	2*
Porcentagem de variância	72.41	26.69
Porcentagem cumulativa de variância	72.41	97.50
Autovetor	Coeficiente de Correlação	
b1	-0.41	0.90 **
b2	-0.25	0.95 **
b3	-0.97 **	0.21
b4	0.93 **	0.16
b5	0.90 **	0.43
NDVI	1 **	0.03
SAVI	0.99 **	0.11
NLI	0.99 **	0.14
Autovalor	Coeficiente de Correlação	
Cp1	1.22	4.38
Cp2	51.06	16.14
Cp3	5.72	6.89
Dp1	30.93	0.38
Dp2	1.42	13.78
Dp3	9.65	58.44

## Análise de componentes principais (Parte II)

Coleção III 65 DAE	Componentes Principais	
	PCI	PCII
Autovalor	4.30 *	1.96 *
Porcentagem de variância	64.42	29.45
Porcentagem cumulativa de variância	64.42	93.87
Autovetor	Coeficiente de Correlação	
b1	-0.20	0.87 **
b2	0.04	0.96 **
b3	-0.87 **	0.36
b4	0.71	0.69
b5	0.94 **	0.22
NDVI	0.99 **	-0.15
SAVI	1 **	-0.06
NLI	1 **	-0.05
Autovalor	Coeficiente de Correlação	
Cp1	33.01	6.57
Cp2	11.55	40.81
Cp3	9.03	13.40
Dp1	1.84	16.31
Dp2	0.00	1.41
Dp3	44.57	21.40
COLEÇÃO IV 75 DAE	Componentes Principais	
	PCI	PCII
Autovalor	6.71*	0.80*
Porcentagem de variância	83.83	9.94
Porcentagem cumulativa de variância	83.83	93.78
Autovetor	Coeficiente de Correlação	
b1	0.78	0.61
b2	0.88**	0.17
b3	-0.85 **	0.45
b4	0.90 **	0.30
b5	0.98 **	-0.06
NDVI	1 **	-0.19
SAVI	1 **	-0.15
NLI	1 **	0.14
Autovalor	Coeficiente de Correlação	
Cp1	23.58	5.88
Cp2	6.71	67.11
Cp3	32.37	3.66
Dp1	0.22	1.39
Dp2	2.60	6.76
Dp3	34.52	2.3

## Análise de componentes principais (Parte III)

COLEÇÃO V 85 DAE	Componentes Principais	
	PCI	PCII
Autovalor	5.44 *	2.17 *
Porcentagem de variância	68.01	27.10
Porcentagem cumulativa de variância	68.01	95.11
Autovetor	Coeficiente de Correlação	
b1	-0.52	0.75

b2	-0.72	0.60
b3	-0.96 **	0.25
b4	0.36	0.88**
b5	0.80	0.59
NDVI	1 **	0.27
SAVI	1 **	0.06
NLI	1 **	0.19
Autovalor	Coeficiente de Correlação	
Cp1	9.84	24.9
Cp2	0.05	17.22
Cp3	19.01	1.64
Dp1	0.00	51.54
Dp2	0.46	3.37
Dp3	70.64	1.33
<b>Coleção VI 95 DAE</b>	Componentes Principais	
	PCI	PCII
Autovalor	4.90	1.94
Porcentagem de variância	61.27	24.25
Porcentagem cumulativa de variância	61.27	85.51
Autovetor	Coeficiente de Correlação	
b1	-0.23	0.95 **
b2	-0.85 **	0.16
b3	0.15	0.98**
b4	-0.87 **	-0.87
b5	-0.85 **	-0.88
NDVI	0.94**	0.94
SAVI	0.93**	0.93
NLI	0.93 **	0.93
Autovalor	Coeficiente de Correlação	
Cp1	5.58	56.93
Cp2	2.26	1.37
Cp3	75.94	1.10
Dp1	1.22	2.99
Dp2	0.02	31.90
Dp3	14.98	5.70

b1: Blue. b2: Verde. b3: Vermelho. b4: Borda do vermelho. b5: Infravermelho próximo.

\*\* *p*valor < 0.01; \* *p* – valor <0,05.