



UNIVERSIDADE DE BRASÍLIA-UNB
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA-FAV
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

**RESPOSTAS FISIOLÓGICAS, RENDIMENTO E QUALIDADE DE
GRÃOS DE GENÓTIPOS DE SOJA E TRIGO SUBMETIDOS A
ESTRESSE HÍDRICO NO CERRADO**

CÁSSIO JARDIM TAVARES

TESE DE DOUTORADO EM AGRONOMIA

BRASÍLIA/DF
MARÇO/2022



UNIVERSIDADE DE BRASÍLIA-UNB
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA-FAV
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

**RESPOSTAS FISIOLÓGICAS, RENDIMENTO E QUALIDADE DE
GRÃOS DE GENÓTIPOS DE SOJA E TRIGO SUBMETIDOS A
ESTRESSE HÍDRICO NO CERRADO**

CÁSSIO JARDIM TAVARES

ORIENTADORA: MARIA LUCRÉCIA GEROSA RAMOS
CO-ORIENTADOR: WALTER QUADROS RIBEIRO JÚNIOR

TESE DE DOUTORADO EM AGRONOMIA

PUBLICAÇÃO: ___/2022

BRASÍLIA/DF
MARÇO/2022



**UNIVERSIDADE DE BRASÍLIA-UNB
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA-FAV
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA**

**RESPOSTAS FISIOLÓGICAS, RENDIMENTO E QUALIDADE DE
GRÃOS EM GENÓTIPOS DE SOJA E TRIGO SUBMETIDOS A
ESTRESSE HÍDRICO NO CERRADO**

CÁSSIO JARDIM TAVARES

**TESE DE DOUTORADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM
AGRONOMIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO
DO GRAU DE DOUTOR EM AGRONOMIA.**

APROVADA POR:

**Maria Lucrecia Gerosa Ramos, Dra. (Orientadora) / Universidade de Brasília /
lucrecia@unb.br**

José Ricardo Peixoto, Dr. (Membro interno) / Universidade de Brasília / peixoto@unb.br

**Adriano Jakelaitis, Dr. (Membro Externo) / IF Goiano /
adriano.jakelaitis@ifgoiano.edu.br**

**Paulo César Ribeiro da Cunha Dr. (Membro Externo) / IF Goiano /
paulo.cunha@ifgoiano.edu.br**

Brasília/DF, 31 de março de 2022

FICHA CATALOGRÁFICA

Tavares, Cássio Jardim

Respostas fisiológicas, rendimento e qualidade de grãos de genótipos de soja e trigo submetidos a estresse hídrico no Cerrado / Cássio Jardim Tavares: Orientadora Maria Lucrecia Gerosa Ramos; Co-orientador Walter Quadros Ribeiro Júnior.

- Brasília, 2022.

149 p.

Tese (Doutorado - Doutorado em Agronomia) --
Universidade de Brasília, 2022.

1. *Glycine max.* 2. *Triticum aestivum*. 3. Índices de vegetação. 4. Tolerância a seca. 5. Automação. I. Ramos, Maria Lucrecia Gerosa, Orient. II. Ribeiro Júnior, Walter Quadros, co-orient. III. Título.

REFERÊNCIA BIBLIOGRÁFICA

TAVARES, C. J. **Respostas fisiológicas, rendimento e qualidade de grãos de genótipos de soja e trigo submetidos a estresse hídrico no Cerrado**. Brasília: Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, 2022, 149p. Tese de Doutorado.

CESSÃO DE DIREITOS

NOME DO AUTOR: CÁSSIO JARDIM TAVARES

TÍTULO DA TESE: Respostas fisiológicas, rendimento e qualidade de grãos de genótipos de soja e trigo submetidos a estresse hídrico no Cerrado.

GRAU: DOUTOR

ANO: 2022

É concedida à Universidade de Brasília permissão para reproduzir cópias desta Tese de Doutorado para única e exclusivamente propósitos acadêmicos e científicos. O autor reserva para si os outros direitos autorais de publicação. Nenhuma parte desta Tese de Doutorado pode ser reproduzida sem a autorização por escrito do autor. Citações são estimuladas, desde que citada a fonte.

Nome: Cássio Jardim Tavares

E-mail: cassio.tavares@ifgoiano.edu.br

Aos meus pais Carlito Luís Tavares (*in memoriam*) e Bernadete Aparecida Jardim Tavares;

Ao irmão Cairo Jardim Tavares.

OFEREÇO

Aos avós Dolvina, Francisco

(*in memoriam*), Adércia (*in memoriam*) e Josias (*in memoriam*).

DEDICO

AGRADECIMENTOS

Agradeço primeiramente à Deus, por todas as graças concedidas.

Agradeço à Universidade de Brasília (UnB) – em especial os integrantes da Pós-Graduação em Agronomia - a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA: Cerrados, Agroenergia, Soja e Trigo) e ao Instituto de pesquisa Max-Planck de Jülich (Alemanha) por abrir às portas e fornecer a infraestrutura para o desenvolvimento das atividades;

Agradeço ao Instituto Federal Goiano pela liberação parcial e incentivo a capacitação dos servidores;

Agradeço a orientadora Profa. Dra. Maria Lucrécia Gerosa Ramos, pelas orientações sempre pertinentes, apoio e por ter acreditado em minha capacidade;

Agradeço ao coorientador Dr. Walter Quadros Ribeiro Júnior, pelas orientações e pela disponibilidade;

Agradeço aos meus pais Carlito Luís Tavares e Bernadete Aparecida Jardim Tavares, ao meu irmão Cairo Jardim Tavares e demais familiares, por me ajudar em todos os momentos desta caminhada e principalmente nos momentos mais difíceis;

Agradeço aos colegas e amigos que de forma direta ou indireta contribuíram para o desenvolvimento dessa tese. Especialmente, gostaria de deixar registrado os nomes dos amigos/colegas Lucas Felisberto, Alberto (Beto), José Reis (Zé Reis), Patrícia, Pedro Valasco, Anderson Silva, Frederico Leite, Simone Estrela, Débora Martins;

Agradeço aos membros avaliadores pelas contribuições pertinentes referentes à tese.

BIOGRAFIA DO AUTOR

Cássio Jardim Tavares, nascido em Pires do Rio - GO em 06 de junho de 1990. Concluiu o ensino fundamental na Escola Municipal Virgínio Vaz da Costa e segundo grau integrado ao curso Técnico em Agropecuária na Escola Família Agrícola de Orizona, ambos no município de Orizona - GO. Concluiu o curso Técnico em Agropecuária em 2007. Graduado em Bacharelado em Agronomia no ano de 2012, pelo Instituto Federal Goiano - Campus Urutaí. Mestre em Ciências Agrárias – Agronomia no ano de 2014, pelo Instituto Federal Goiano – Campus Rio Verde atuando na linha de pesquisa: Tecnologias sustentáveis em sistemas de produção e uso do solo e água. Em janeiro de 2015 tomou posse como Professor do Ensino Básico, Técnico e Tecnológico no Instituto Federal Goiano – Campus Posse. Em 2018, ingressou no Programa de Pós-Graduação em Agronomia, *Stricto Sensu*, da Universidade de Brasília (UnB), área de concentração: Produção sustentável.

RESUMO GERAL

TAVARES, CÁSSIO JARDIM. Universidade de Brasília, 31 de março de 2022. Respostas fisiológicas, rendimento e qualidade de grãos de genótipos de soja e trigo submetidos a estresse hídrico no Cerrado. Orientador: Dra. Maria Lucrecia Gerosa Ramos. Coorientador: Dr. Walter Quadros Ribeiro Júnior.

A seleção de genótipos de soja e de trigo tolerantes à seca em plantio de sequeiro e com maior eficiência no uso de água no caso de se utilizar irrigação, é uma prioridade de pesquisa, especificamente em regiões onde ocorre precipitações pluviométricas irregulares ou em locais onde as mudanças climáticas devem resultar em redução na disponibilidade de água, pois essa situação reduz a produtividade e a qualidade de grãos nessas culturas. Nesse contexto, o uso de novas tecnologias que permitam mitigar os efeitos da seca e ainda, a seleção eficiente de materiais geneticamente superiores em relação à tolerância a seca é de suma importância. Neste trabalho, objetivou-se: (1) avaliar as respostas de cultivares de soja ao estresse hídrico, em relação ao rendimento e à qualidade dos grãos cultivados em condições típicas de Cerrado (Experimento 01); (2) estimar as correlações canônicas entre índices de vegetação e variáveis fisiológicas, componentes de rendimento e qualidade de grãos de cultivares de soja submetidos ao estresse hídrico no Cerrado (Experimento 01); (3) avaliar as respostas fisiológicas, espectrais e agronômicas de genótipos de trigo ao estresse hídrico, cultivados em condições típicas de Cerrado (experimento 02). Os experimentos foram conduzidos na Embrapa Cerrados, Planaltina-DF, em delineamento em blocos ao acaso (DBC), em esquema de parcelas subdivididas, com três repetições, em dois anos de cultivo (maio a setembro de 2018 e de 2019). Nas parcelas foram alocados os genótipos (experimento 01: NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR e, experimento 02: BRS 254; BRS 264; CPAC 01019; CPAC 01047; CPAC 07258; CPAC 08318; CPAC 9110; BRS 394 (bióticos irrigados) e Aliança; BR 18 (Terena); BRS 404; MGS Brilhante; PF 020037; PF 020062; PF 120337; PF 368; PF 080492; TBIO Sintonia (biótipos de sequeiro)) e, nas subparcelas os quatro regimes hídricos (experimento 01: RH1, RH2, RH3 e RH4, representando 31, 44, 64 e 100% da reposição da evapotranspiração da cultura – ETc e, experimento 02: 22, 43, 81 e 100% da reposição da evapotranspiração da cultura - ETc). Foram realizadas avaliações das características de trocas gasosas, índices de vegetação, componentes de produção e qualidade dos grãos. Os dados observados foram submetidos à análise de variância conjunta multivariada, por safra. No experimento 02 realizou-se agrupamento de genótipos pelo método de Ward com base na distância de Mahalanobis. Em ambos os experimentos, os tratamentos (genótipos e regimes hídricos) foram representados em *biplot* a partir da decomposição em valores singulares da matriz de médias dos tratamentos nos dois anos. Em ambas as culturas, a condição de estresse hídrico afetou negativamente as trocas gasosas, os índices de vegetação e o rendimento dos grãos, mas em grau diferente nos genótipos estudados. Nessa condição, observa maior eficiência no uso da água e maior massa de raízes nos genótipos de trigo. Índices espectrais são importantes na divergência dos genótipos e os índices baseados na banda do infravermelho próximo são relacionados com respostas fisiológicas e agronômicas de trigo e soja. Os genótipos de trigo (BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia) são mais afetados pela indisponibilidade de água. As cultivares de soja BRS 7280RR e NA 5909RG apresentam maior desempenho produtivo tanto em maior quanto em menor disponibilidade hídrica.

Palavras-chave: *Glycine max*, *Triticum aestivum*, índices de vegetação, tolerância à seca, trocas gasosas, automação.

ABSTRACT

TAVARES, CASSIO JARDIM. University of Brasilia, march 31, 2022. Physiological, yield and grain quality responses in soybean and wheat genotypes subjected to water stress in the Cerrado. Advisor: Dr. Maria Lucrécia Gerosa Ramos. Co-Advisor: Dr. Walter Quadros Ribeiro Júnior.

The selection of drought-tolerant soybean and wheat genotypes for rainfed plant period and with greater efficiency in the use of water for irrigated conditions, is a research priority, specifically in regions where irregular rainfall occurs or in places where climate change should result in a reduction in water availability, as this situation reduces productivity and grain quality in these crops. In this context, the use of new technologies that mitigate the effects of drought and the efficient selection of genetically superior materials in relation to drought tolerance is paramount. This work aimed to: (1) evaluate the responses of soybean cultivars to water stress, in relation to yield and quality of grains cultivated under typical Cerrado conditions (Experiment 01); (2) estimate the canonical correlations between vegetation indices and physiological variables, yield components and grain quality of soybean cultivars to water stress in the Cerrado (Experiment 01); (3) evaluate the physiological, spectral and agronomic responses of wheat genotypes to water stress, cultivated under typical Cerrado conditions (experiment 02). The experiments were carried out at Embrapa Cerrados, Planaltina-DF, in a randomized block design (DBC), in a split-plot scheme, with three replications, in two years of cultivation (May to September of 2018 and 2019). The genotypes were allocated in the plots (experiment 01: NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR and, experiment 02: BRS 254; BRS 264; CPAC 01019; CPAC 01047; CPAC 07258; CPAC 08318; CPAC 9110; BRS 394 (irrigated biotics) and Aliança; BR 18 (Terena); BRS 404; MGS Brilhante; PF 020037; PF 020062; PF 120337; PF 368; PF 080492; TBIO Sintonia (rainfed biotypes)) and, in the subplots, the four water regimes (experiment 01: RH1, RH2, RH3 and RH4, representing 31, 44, 64 and 100% of the replacement of crop evapotranspiration - ET_c and, experiment 02: 22, 43, 81 and 100% of crop evapotranspiration replacement - ET_c). Assessments of gas exchange characteristics, vegetation indexes, production components, and grain quality were carried out. The observed data were submitted to joint multivariate analysis of variance by crop. In experiment 02, genotypes were grouped using the Ward method based on the Mahalanobis distance. In both experiments, the treatments (genotypes and water regimes) were represented in biplot, from the decomposition into singular values of the matrix of means of the treatments in the two years. In both cultures, the water stress condition negatively affected gas exchange, vegetation rates and grain yield, but to a different degree in the studied genotypes. In this condition, it observes greater water use efficiency and greater mass of roots in the wheat genotypes. Spectral indices are important in the divergence of genotypes, and indices based on the near-infrared band are related to physiological and agronomic responses of wheat and soybean. Wheat genotypes (BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia) are most affected by water unavailability. Soybean cultivars BRS 7280RR and NA 5909RG present greater productive performance in both higher and lower water availability.

Keywords: *Glycine max*, *Triticum aestivum*, vegetation indexes, drought tolerance, gas exchange; automation.

SUMÁRIO DE TABELAS

CAPÍTULO I

Tabela 1. Características espectrais avaliadas e suas respectivas fórmulas de cálculo.....	87
Tabela 2. Médias das variáveis de índices de vegetação, trocas gasosas e rendimento quântico máximo do fotossistema II em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.....	88
Tabela 3. Médias das variáveis morfológicas, rendimento e qualidade grãos em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.....	89

CAPÍTULO II

Tabela 1. Médias das variáveis morfológicas, rendimento e qualidade grãos em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.....	114
Tabela 2. Médias das variáveis de índices de vegetação (câmara multiespectral), trocas gasosas e rendimento quântico máximo do fotossistema II em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.....	115
Tabela 3. Correlações canônicas e primeiros pares canônicos estimados entre variáveis espectrais (<i>Índices de vegetação</i>) e variáveis agronômicas (<i>Componentes de rendimento + Qualidade de grãos</i>) e do IRGA em soja.....	116

CAPÍTULO III

Tabela 1. Valores médios dos índices vegetativos e produtividade do trigo em função dos grupos de genótipos e regimes hídricos nas safras 2018 e 2019.....	142
Tabela 2. Valores médios para as variáveis morfofisiológicas e índice de tolerância à seca do trigo em função dos grupos de genótipos e regimes hídricos nas safras 2018 e 2019.....	143
Tabela 3. Importância relativa (percentagem) de variáveis no distanciamento entre genótipos pelo Critério de Singh (1981).....	143

SUMÁRIO DE FIGURAS

CAPÍTULO I

- Figura 1.** Precipitação e temperatura média obtidos em uma estação meteorológica automatizada localizada ao lado do experimento, nos anos de 2018 e 2019 e uma série histórica (1974 – 2019). 90
- Figura 2.** Resumo gráfico das subunidades experimentais (RH1, RH2, RH3 e RH4 - 31, 44, 64 e 100% de reposição da ETc, respectivamente) e da barra de irrigação na cultura da Soja. ... 90
- Figura 3.** *Biplot* para médias de regimes hídricos (31, 44, 64 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente) e cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR) a partir de variáveis: altura de Plantas (AP); Altura Inserção primeira Vagem (A1); Diâmetro do Colmo (DC); Número de vagens (NV); grão por vagem (GV); Umidade dos Grãos (UG); Massa de Mil Grãos (MMG); Rendimento de Grãos (RG); Eficiência no Uso de Água (EUA); Porcentagem de óleo (O); Porcentagem de Proteína (P); Peso Hectolitro (PH); Porcentagem de Germinação (G). Índice de Vegetação por Diferença Normalizada Verde (GNDVI); Índice Fotoquímico de Reflectância (PRI); Green-Red Vegetation Index (GRVI); Diferença Normalizada do Red Edge (NDRE); Índice de Vegetação por Diferença Normalizada (NDVI); Normalized Difference Water Index (NDWI); Difference Vegetation Index (DVI); Índice de Vegetação Ajustado ao Solo (SAVI); Optimized Soil Adjusted Vegetation Index (OSAVI); The transformed Chlorophyll Absorption and Reflectance Index (TCARI); Relação TCARI/OSAVI (To); Assimilação líquida de CO₂ (A); Condutância Estomática (Gs); Transpiração (E); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Eficiência de uso de água intrínseca (iEUA). 91
- Figura 4.** Correlograma de Pearson entre variáveis que representam as variáveis: altura de Plantas (Ap); Altura Inserção primeira Vagem (A1); Diâmetro do Colmo (DC); Número de vagens (NV); grão por vagem (GV); Umidade dos Grãos (UG); Massa de Mil Grãos (MMG); Rendimento de Grãos (RG); Eficiência no Uso de Água (EUA); Porcentagem de óleo (O); Porcentagem de Proteína (P); Peso Hectolitro (PH); Porcentagem de Germinação (G); Índice de Vegetação por Diferença Normalizada Verde (GNDVI); Índice Fotoquímico de Reflectância (PRI); Green-Red Vegetation Index (GRVI); Diferença Normalizada do Red Edge (NDRE); Índice de Vegetação por Diferença Normalizada (NDVI); Normalized Difference Water Index (NDWI); Difference Vegetation Index (DVI); Índice de Vegetação Ajustado ao Solo (SAVI); Optimized Soil Adjusted Vegetation Index (OSAVI); The transformed Chlorophyll Absorption and Reflectance Index (TCARI); Relação TCARI/OSAVI (To); Assimilação líquida de CO₂ (A); Condutância Estomática (Gs); Transpiração (E); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Eficiência de uso de água intrínseca (iEUA) em função dos regimes hídricos (31, 44, 64 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente) e cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR). 92
- Figura 5.** Equações de regressão e os respectivos coeficientes de determinação (R²) das variáveis: A- Coordenada Principal 1 - variável latente (Coord. 1), B- Rendimento de Grãos, C- Assimilação Líquida de CO₂ (A), D - Eficiência no Uso de Água (EUA) e, E - Índice de Vegetação por Diferença Normalizada (NDVI) em função dos regimes hídricos (RH1, RH2,

RH3 e RH4 - 31, 44, 64 e 100% ETc, respectivamente) e cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR)..... 93

CAPÍTULO II

Figura 1. Precipitação e temperatura média obtidos em uma estação meteorológica automatizada localizada próxima ao experimento, nos anos de 2018 e 2019 e uma série histórica (1974 – 2019). 112

Figura 2. Rede de correlações entre índices espectrais (*Índices de vegetação + Irga*) e variáveis agronômicas de soja (*Componentes de rendimento + Qualidade de grãos*). As linhas vermelhas representam correlações negativas e as verdes representam correções positivas. A espessura da linha é proporcional à magnitude da correlação. As linhas em destaque apresentam correlação em módulo maior que 0,6. Variáveis: Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI), Green-Red Vegetation Index (GRVI), Difference Vegetation Index (DVI), Normalized Difference Water Index (NDWI), Normalized Difference Red Edge (NDRE), (Ratio Vegetation Index (RVI), Soil Adjusted Vegetation Index (SAVI), Photochemical Reflectance Index (PRIc), Optimized Soil Adjusted Vegetation Index (OSAVI), Chlorophyll Absorption and Reflectance Index (TCARI), Relação TCARI/OSAVI (To), Índice de Reflectância Fotoquímica (PRIc), Assimilação líquida de CO₂ (A); Condutância Estomática (gs); Transpiração (E); Rendimento Quântico Máximo do Fotossistema II (Fv_Fm), Concentração Interna de CO₂ (CI), Altura de Plantas (AP), Altura Inserção Primeira Vagem (A1), Diâmetro do Coleto (DC), Número de Vagens (NV), Grão por Vagem (GV), Número de Nós (NN), Massa de Mil Grãos (MMG), Rendimento de Grãos (RG), Eficiência no Uso de Água (EUA), Teor de óleo (O); Teor de Proteína (P); Peso Hectolitro (PH); Germinação (G), e Sementes Duras (D). 113

CAPÍTULO III

Figura 1. Precipitação e temperatura média obtidos em uma estação meteorológica automatizada localizada ao lado do experimento, nos anos de 2018 e 2019 e uma série histórica (1974-2019)..... 144

Figura 2. Dendrograma obtido com o método de Ward com base na distância generalizada de Mahalanobis para agrupamento de 18 genótipos de trigo. Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; grupo 2: BR 18_Terena; MGS Brillhante; PF 020037; PF 120337; grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 368; TBIO Sintonia. 145

Figura 3. *Biplot* para médias de regimes hídricos (RH1, RH2, RH3 e RH4 - 22, 43, 81, 100% ETc, respectivamente) e grupos de genótipos de trigo (1, 2, 3) com base nos escores (pesos) das variáveis: Relação RA/PA (RA.PA); Razão Clorofila a/b (Cha.b); Eficiência no uso da água (EUA); Relação TCRI/OSAVI (TO); Eficiência intrínseca do uso da água (iEUA - A/gs); Taxa de transporte de elétrons (ETR); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Umidade do grão (UG); Clorofila b (Chb); Clorofila a (Cha); Corofila total (Cht); Índice de Resistência à Seca (DRI); Massa de raiz (RA); Concentrações internas de CO₂ (Ci); Massa de mil grãos (MMG); Massa de parte aérea (PA); Rendimento Quântico Efetivo do Fotossistema (Fv'/Fm'); Condutância Estômica (gs); Transpiração (E); Rendimento de grãos (RG);

Assimilação Líquida de CO₂ (A); The Transformed Chlorophyll Absorption and Reflectance Index (TCARI); Green red vegetation index (GRVI); Normalized difference vegetation index (NDVI); Optimized Soil Adjusted Vegetation Index (OSAVI); Soil adjusted vegetation index (SAVI); Photochemical Physiological Reflectance Index (PRI); Green normalized difference vegetation index (GNDVI); Red Edge Normalized Difference (NDRE); Difference vegetation index (DVI). Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; Grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; Grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia. . 146

Figura 4. Correlograma de Pearson entre variáveis fisiológicas, espectrais e agrônômicas em função dos regimes hídricos (22, 43, 81 e 100% da reposição ETc - RH1, RH2, RH3 e RH4, respectivamente) e grupos de genótipos de trigo (1, 2, 3), com base nos escores das coordenadas principais das variáveis: Relação RA/PA (RA.PA); Razão Clorofila a/b (Cha.b); Eficiência no uso da água (EUA); Relação TCRI/OSAVI (TO); Eficiência intrínseca do uso da água (iEUA - A/g_s); Taxa de transporte de elétrons (ETR); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Umidade do grão (UG); Clorofila b (Chb); Clorofila a (Cha); Corofila total (Cht); Índice de Resistência à Seca (DRI); Massa de raiz (RA); Concentrações internas de CO₂ (Ci); Massa de mil grãos (MMG); Massa de parte aérea (PA); Rendimento Quântico Efetivo do Fotossistema (Fv'/Fm'); Condutância Estômica (g_s); Transpiração (E); Rendimento de grãos (RG); Assimilação Líquida de CO₂ (A); The Transformed Chlorophyll Absorption and Reflectance Index (TCARI); Green red vegetation index (GRVI); Normalized difference vegetation index (NDVI); Optimized Soil Adjusted Vegetation Index (OSAVI); Soil adjusted vegetation index (SAVI); Photochemical Physiological Reflectance Index (PRI); Green normalized difference vegetation index (GNDVI); Red Edge Normalized Difference (NDRE); Difference vegetation index (DVI). Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; Grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; Grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia. 147

Figura 5. Equações de regressão e os respectivos coeficientes de determinação (R²) das variáveis: A- Coordenada Principal 1 - variável latente (Coord. 1), B- Rendimento de Grãos, C- Assimilação líquida de CO₂, D- Índice de Vegetação por Diferença Normalizada (NDVI), E- Eficiência no Uso de Água (EUA) e, F- Eficiência intrínseca no Uso de água (iEUA) em função dos regimes hídricos (RH1, RH2, RH3 e RH4 - 22, 43, 81, 100% ETc, respectivamente) e dos grupos de genótipos de trigo (1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; 2: BR 18; MGS Brilhante; PF 020037; PF 120337; 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 368; TBIO Sintonia). 148

LISTA DE SÍMBOLOS, SIGLAS, ABREVIACÕES E UNIDADES

Símbolo / Sigla	Significado	Unidade
P	Fósforo	mg dm ⁻³
Ca	Cálcio	cmol _c dm ⁻³
Mg	Magnésio	cmol _c dm ⁻³
Al	Alumínio	cmol _c dm ⁻³
N	Nitrogênio	%
MO	Matéria orgânica	%
pH	Potencial de hidrogênio	
b.u.	base úmida	%
US	Umidade do solo	%
RG	Rendimento de grãos	kg ha ⁻¹
MMG	Massa de mil grãos	g
PA	Massa seca da parte aérea	g
RA	Massa seca de raiz	g
DC	Diâmetro do colmo	cm
A	Taxa fotossintética	μmol CO ₂ m ⁻² s ⁻¹
E	Taxa transpiratória	mmol H ₂ O m ⁻² s ⁻¹
g _s	Condutância estomática	mol H ₂ O m ⁻² s ⁻¹
CLa	Clorofila <i>a</i>	μg cm ⁻²
CLb	Clorofila <i>b</i>	μg cm ⁻²
ETR	Taxa de transporte de elétrons	
F _v /F _m	Rendimento quântico potencial fotossistema II	
G	Gramas	
Kg	Quilograma	
Há	Hectare	
Mm	Milímetros	
%	Porcentagem	
Cm	Centímetros	
cm ²	Centímetro quadrado	
cm ³	Centímetro cúbico	

cmolc kg ⁻¹	Centimol por quilograma
DAE	Dias após emergência
DAS	Dias após semeadura
EUA	Eficiência no uso de água
AP	Altura de plantas
A1	Altura inserção da primeira vagem
NV	Número de vagens
GV	Número de grãos por vagem
IV	Índice de vegetação
DVI	Difference Vegetation Index
NDWI	Normalized Difference Water Index
NDRE	Normalized Difference Red Edge
SAVI	Soil Adjusted Vegetation Index
PRI	Photochemical Physiological Reflectance Index
OSAVI	Optimized Soil Adjusted Vegetation Index
TCARI	Chlorophyll Absorption and Reflectance Index
TO	Relação TCARI/OSAVI
VANT	Veículo aéreo não tripulado
SR	Sensoriamento Remoto
NIR	Infravermelho próximo

SUMÁRIO

RESUMO GERAL	VI
ABSTRACT	VII
SUMÁRIO DE TABELAS	VIII
SUMÁRIO DE FIGURAS	IX
LISTA DE SÍMBOLOS, SIGLAS, ABREVIACÕES E UNIDADES	XII
SUMÁRIO	XIV
1. INTRODUÇÃO GERAL	16
1.1. OBJETIVO GERAL.....	18
1.1.1. OBJETIVOS ESPECÍFICOS	18
1.2. HIPÓTESES	18
2. REVISÃO DE LITERATURA	19
2.1. A CULTURA DA SOJA	19
2.2. A CULTURA DO TRIGO.....	22
2.3. MELHORAMENTO GENÉTICO DE PLANTAS VISANDO TOLERÂNCIA À SECA	25
2.4. ESTRESSE HÍDRICO.....	28
2.5. SENSORIAMENTO REMOTO	31
2.5.1. SENSORES	32
2.5.2. ÍNDICES DE VEGETAÇÃO	34
2.6. TROCAS GASOSAS E FLUORESCÊNCIA DA CLOROFILA A	39
2.7. REFERÊNCIAS	44
CAPÍTULO 1. RESPOSTAS FISIOLÓGICAS, RENDIMENTO E QUALIDADE DE GRÃOS DE CULTIVARES DE SOJA SUBMETIDOS A ESTRESSE HÍDRICO NO CERRADO	61
1.1. INTRODUÇÃO	62
1.2. MATERIAL E MÉTODOS.....	64
1.3. RESULTADOS E DISCUSSÃO	69
1.4. CONCLUSÕES	77
1.5. REFERÊNCIAS	78
1.6. APÊNDICE	86
CAPÍTULO 2 - CORRELAÇÃO CANÔNICA ENTRE VARIÁVEIS ESPECTRAIS, FISIOLÓGICAS, DE RENDIMENTO E QUALIDADE DE GRÃOS DE CULTIVARES DE SOJA SUBMETIDOS A ESTRESSE HÍDRICO NO CERRADO	94
2.1. INTRODUÇÃO	95
2.2. MATERIAL E MÉTODOS.....	96
2.3. RESULTADOS E DISCUSSÃO	100
2.4. CONCLUSÕES	103

2.5. REFERÊNCIAS	104
2.6 APÊNDICE	111
CAPÍTULO 3 - RESPOSTAS FISIOLÓGICAS, AGRONÔMICAS E ESPECTRAIS DE GENÓTIPOS DE TRIGO SUBMETIDOS A ESTRESSE HÍDRICO NO CERRADO.	117
3.1. INTRODUÇÃO	118
3.2. MATERIAL E MÉTODOS.....	119
3.3. RESULTADOS E DISCUSSÃO	126
3.4. CONCLUSÕES	133
3.5. REFERÊNCIAS	134
3.6 APÊNDICE	141
CONSIDERAÇÕES FINAIS.....	149

1. INTRODUÇÃO GERAL

O trigo (*Triticum aestivum* L.) é a segunda espécie vegetal mais cultivada do mundo, responsável por 19% das calorias na dieta humana global, uma vez que é rico em carboidratos e possui um maior teor de proteínas que outros cereais, como arroz, milho e centeio (LIU et al., 2016; ZÖRB et al., 2018).

A soja (*Glycine max* (L.) Merrill) é a oleaginosa mais cultivada no mundo, ocupando papel de destaque na economia mundial. Os grãos da soja processados pela agroindústria são uma das principais fontes de proteína e óleo para a alimentação humana e animal (representa em torno de 70% da composição das rações de animais) (WANG et al., 2016).

Ambas as culturas apresentam perdas no seu rendimento máximo devido a estresses abióticos que afetam seu crescimento no campo, sendo a seca o principal fator ambiental limitante ao desenvolvimento das plantas (FITA et al., 2015). A intensidade de longos e severos períodos de estiagem durante o ciclo dessas culturas deve aumentar devido às mudanças climáticas globais em curso, o que deverá afetar diretamente o rendimento e a qualidade de grãos (LESK et al., 2016).

Assim, a obtenção por genótipos de trigo e soja tolerantes à seca em cultivos de sequeiro, possui relevância econômica, ambiental e social, garantindo a produtividade das culturas. No caso de cultivos irrigados, o aumento da eficiência no uso de água também contribui para a segurança alimentar humana e animal.

Os genótipos tolerantes ao déficit hídrico podem ser identificados através de uma combinação de variáveis, a saber: a eficiência de uso da água (ZHAO et al., 2020), os componentes de produtividade (ANWAAR et al., 2020), os índices de vegetação e pigmentos (ANDEREGG et al., 2020; YANG et al., 2020) e as trocas gasosas e fluorescência da clorofila

a (OUYANG et al., 2017; AHMED et al., 2020), que podem correlacionar-se de forma positiva ou negativa com o rendimento e qualidade dos grãos (MEENA et al., 2019).

Novas tecnologias e metodologias que mensuram essas variáveis devem oferecer vantagens em relação aos níveis de rendimento, aplicabilidade em condições de campo (em diversas condições climáticas) e rapidez na obtenção dessas informações com as já existentes e consolidadas. A utilização de ferramentas que proporcionam uma rápida avaliação e que não sejam invasivas e destrutivas, em qualquer fase de desenvolvimento da cultura e com elevada precisão sobre as características das plantas em relação a fatores abióticos e bióticos (QIU et al., 2018), vem sendo utilizadas nos estudos da interação planta ambiente.

Dentre essas ferramentas, o uso de sensores na agricultura pode fornecer informações valiosas sobre a fisiologia da planta sob estresse hídrico, através da detecção de alterações relacionadas à estrutura, pigmentos e eficiência fotossintética da planta (SOBEJANO-PAZ et al., 2020).

A utilização de sensores montados em plataformas terrestres (ANDRADE-SANCHEZ et al., 2014), ou veículos aéreos não tripulados (HAGHIGHATTALAB et al., 2016) apresentam a vantagem de uma avaliação rápida, não destrutiva e com elevada precisão. Contudo, existe a necessidade de se validar a eficiência dessas ferramentas. Dentre esses sensores, há as câmeras multiespectrais acopladas em veículos não tripulados, que podem ser utilizadas na seleção de cultivares adaptadas as diferentes condições de cultivo (KELLER et al., 2018), sendo uma ferramenta indispensável em programas de melhoramento genético.

Assim, o entendimento das alterações promovidas pelo déficit hídrico nas características morfofisiológicas, espectrais e de rendimento, em genótipos de trigo e soja, são importantes na seleção de cultivares e no gerenciamento e tomadas de decisão em relação ao manejo dessas culturas.

1.1. Objetivo Geral

- Avaliar as alterações morfofisiológicas, rendimento e qualidade de grãos em genótipos de soja e trigo submetidos a quatro regimes hídricos no Cerrado.

1.1.1. Objetivos Específicos

- Avaliar o potencial produtivo de seis cultivares de soja, sob quatro regimes hídricos em condições de campo;

- Avaliar o potencial produtivo de dezoito genótipos de trigo, sob quatro regimes hídricos em condições de campo;

- Verificar a influência do estresse hídrico nas trocas gasosas, nos índices espectrais e nos parâmetros de fluorescência da clorofila *a* de genótipos de trigo e soja;

- Avaliar o efeito do déficit hídrico na qualidade de grãos de genótipos de soja;

- Validar o uso de índices de vegetação extraídos de sensores multiespectrais na identificação de genótipos em condição de estresse hídrico.

1.2. Hipóteses

- Os genótipos de soja e trigo testados possuem potencial produtivo e morfofisiológico distintos em diferentes níveis de água;

- Respostas fisiológicas não destrutivas de soja e trigo, assim como os índices de vegetação, estão relacionadas à disponibilidade de água no solo e podem ser utilizadas para discriminar genótipos tolerantes e com maior eficiência no uso de água.

2. REVISÃO DE LITERATURA

2.1. A Cultura da Soja

A soja (*Glycine max* (L.) Merrill) é a oleaginosa mais cultivada no mundo, ocupando papel de destaque na economia mundial. Devido à sua ampla adaptabilidade climática, à diversidade de genótipos e ao alto valor nutritivo dos grãos, o seu cultivo ocorre em boa parte das regiões do planeta. Estima-se que no Brasil, na safra 2021/2022 serão cultivados aproximadamente 40,4 milhões de hectares de soja com produção próxima de 140,5 milhões de toneladas de grãos (CONAB, 2022).

A soja é uma planta herbácea e pertence à classe Rosidae, ordem Fabales, família Fabaceae, subfamília Papilionoideae, tribo Phaseoleae (TRACE, 2021). Originou-se na costa leste da Ásia de onde ocorreu a sua dispersão geográfica para o Norte da China, Coréia e Japão (século III d.C) e para o ocidente (entre os séculos XIV e XIX) (FREITAS, 2011).

Os grãos da soja processados pela agroindústria são uma das principais fontes de proteína e óleo para alimentação humana e animal (WANG et al., 2016; RIGO et al., 2018). Além disso, a soja está presente na indústria química e na produção de biodiesel, resultado de um ascendente interesse mundial na produção e no consumo de energia renovável (ROSA et al., 2020).

Seu ciclo é dividido em estádios fenológicos, com terminologia precisa e universal, capaz de descrever um único indivíduo, ou uma lavoura inteira, de qualquer cultivar e assim é possível entender melhor os processos morfofisiológicos que ocorrem na planta (FEHR e CAVINNES, 1977): Estádio 1 (VE) – Estádio vegetativo de emergência dos cotilédones, estes se encontram acima da superfície do solo e formam um ângulo 90° com seus respectivos hipocótilos; Estádio 2 (VC) – Os cotilédones encontram-se completamente abertos e expandidos (as bordas de suas folhas unifolioladas não mais se tocam).

A partir do VC, as subdivisões dos estádios vegetativos são numeradas sequencialmente (V1, V2, V3, V4, V5, V6, ... Vn), em que n é o número de nós acima do nó cotiledonar com folha completamente expandida). Assim, uma plântula está em V1 quando as folhas unifolioladas (opostas, no primeiro nó foliar) estiverem completamente desenvolvidas, isto é, quando os bordos dos folíolos da primeira folha trifoliolada não mais se tocarem, e assim, sucessivamente. Desta forma, a depender do hábito de crescimento da cultura, indeterminado ou determinado, a planta poderá lançar trifólios por mais tempo (indeterminado), ou ainda, ter um número de trifólios definido por características inerentes ao genótipo e o último trifólio transforma-se em primórdio floral (determinado). Os estádios reprodutivos abrangem quatro distintas fases do desenvolvimento reprodutivo da planta, ou seja, florescimento (R1 e R2), desenvolvimento da vagem (R3 e R4), enchimento dos grãos (R5 e R6) e maturação (R7 e R8).

O desenvolvimento dos grãos é dividido ainda, segundo Ritchie et al. (1977), em outras 5 fases, numeradas de R5.1 a R5.5, que levam em consideração a percentagem de grãos granados, de 10%, 11 a 25%, 26 a 50%, 51 a 75% e 76 a 100% para as fases R5.1, R5.2, R5.3, R5.4 e R5.5, respectivamente.

Apesar de ser uma cultura bastante estudada, a soja tem sua produtividade reduzida por diversos fatores, devido à interação entre genótipo e ambiente. Fatores edafoclimáticos, tais como fotoperíodo, precipitação, radiação solar, temperatura, umidade e fertilidade do solo; e a presença de insetos pragas, patógenos, plantas daninhas, bem como os fatores genéticos, afetam o rendimento e a qualidade de grãos (BEEBE et al., 2014).

Como aproximadamente 86% da produção mundial de soja está concentrada em áreas de cultivo em três países, Brasil, Estados Unidos e Argentina, (CONAB, 2021), quaisquer flutuações ambientais nestes países podem representar grandes perdas na produção e produtividade a nível mundial. No entanto, as maiores variações na produtividade em relação

aos efeitos climáticos ocorrem na Argentina (~47%) e as menores variações no rendimento desta cultura ocorrem no Brasil (26-34%) (RAY et al., 2015).

Dentre os principais efeitos climáticos destacam-se o déficit hídrico e o fotoperíodo, uma vez que estes fatores limitantes podem comprometer a produtividade da cultura da soja em até 80%, afetando seu crescimento, desenvolvimento e com isso sua produtividade e a qualidade dos grãos (ENGELS et al., 2017).

A disponibilidade hídrica é considerada o fator climático que mais afeta a produtividade da soja, com maior importância, particularmente, em dois períodos do desenvolvimento da cultura: germinação-emergência (4 a 5 dias) e floração-enchimento de grãos. No primeiro, o conteúdo de água disponível no solo deve ficar entre 50 e 85% do total máximo de água para assegurar uma boa germinação (SENTELHAS et al., 2015).

No segundo período, déficits hídricos expressivos, durante a floração e o enchimento de grãos, provocam alterações fisiológicas na planta (fechamento estomático e o enrolamento de folhas) causando a queda prematura das folhas e de flores e abortamento de vagens, grãos maus formados e redução do rendimento de grãos (SENTELHAS et al., 2015).

Além disso, o déficit hídrico minimiza a disponibilidade de nutrientes essenciais e reduz a fixação biológica do nitrogênio (FBN) (CEREZINI et al., 2016), aumenta a abscisão foliar e antecipa o ciclo e, reduz a área foliar (CHACON et al., 2017), o rendimento e qualidade dos grãos (ENGELS et al., 2017).

A necessidade total de água na cultura da soja, para obtenção do máximo rendimento, varia entre 450 a 800 mm ciclo⁻¹ dependendo das condições ambientais, características de solo, manejo da cultura e da cultivar (EDREIRA et al., 2017).

Adicionalmente ao déficit hídrico, geralmente ocorre o aumento de temperatura nas áreas de cultivo. A soja adapta-se melhor a temperaturas entre 20 e 30 °C; e possui temperaturas ideais para emergência (25 °C), crescimento e desenvolvimento (30 °C) e para floração (acima

de 13 °C). Temperaturas acima de 40 °C têm efeito adverso na taxa de crescimento, provocando distúrbios na floração e diminuição da capacidade de retenção de vagens; abaixo de 10 °C o crescimento vegetativo da soja é mínimo ou nulo (NAOE et al., 2017).

Para minimizar os efeitos do déficit hídrico deve-se semear cultivares adaptadas às condições edafoclimáticas de cada região; na época recomendada, com menor risco climático e adequada umidade no solo; bem como, adotar práticas que favoreçam o armazenamento de água pelo solo (MARIANI e FERRANTE, 2017).

2.2. A Cultura do Trigo

O trigo (*Triticum aestivum* L.) é a segunda espécie mais cultivada do mundo, com uma área estimada em aproximadamente 200 milhões de hectares (ZÖRB et al., 2018). O consumo de grãos de trigo é responsável por 19% das calorias na dieta humana global, uma vez que é rico em carboidratos e possui um maior teor de proteínas que outros cereais, como arroz, milho e centeio (LIU et al., 2016; ZÖRB et al., 2018).

É uma planta herbácea pertencente à classe Liliopsida (Monocotiledônea), Família Poaceae (gramínea), tribo Triticeae (TRACE, 2021). A planta resultou do cruzamento de espécies silvestres de gramíneas existentes na região dos rios Tigre e Eufrates (atual Iraque), por volta de 10.000 a 15.000 a.C (BOSCHINI, 2011). Possui ampla adaptação edafoclimática, sendo cultivado desde regiões de clima desértico, em alguns países do Oriente Médio, até regiões com alto índice de precipitação, como na China e Índia (CONAB, 2021).

No Brasil, o trigo é cultivado desde a região Sul até a região de Cerrados, no Brasil Central. Os principais estados brasileiros produtores de trigo são o Rio Grande do Sul, Santa Catarina, Paraná, São Paulo, Mato Grosso do Sul, Mato Grosso, Minas Gerais, Goiás, Distrito Federal e Bahia, destacando-se a região Sul com 90% da produção do país (CONAB, 2021). O Brasil possui uma demanda anual em torno de 12 milhões de toneladas de grãos de trigo, mas

produz menos da metade de sua necessidade e a outra metade é importada (SILVA et al., 2017), principalmente, da Argentina e da Rússia, devido a acordos comerciais com esses países.

O Cerrado brasileiro (área aproximada de 2.036.448 km², ocupando 23,9% do território nacional) apresenta-se como uma alternativa para a produção de trigo em cultivo de sequeiro ou irrigado, por dispor de condições diferenciadas de clima e solo, comparado às regiões tradicionais de cultivo (GOMES et al., 2019). Nessa região, o trigo pode ser cultivado em duas épocas, no inverno (irrigado) e no verão em condições de safrinha (sequeiro).

No inverno, sob condições de irrigação, as plantas apresentam altas produtividades e devem ter eficiência no uso da água. Diferentemente, o cultivo durante o verão no final da estação chuvosa resulta na sementeira do trigo na entressafra, e a principal limitação são os períodos de seca, que requerem plantas tolerantes à seca (SOARES et al., 2021).

A sementeira do trigo de verão (safrinha) depende entre outros fatores do ciclo do cultivo da safra anterior, da disponibilidade hídrica e de cultivares tolerantes à seca e doenças como a brusone (*Pyricularia oryzae*), haja visto que, são os principais fatores limitantes para o cultivo de trigo na safrinha (PEREIRA et al., 2019).

O trigo irrigado, nessa região tem alcançado altas produtividades, acima de 7.000 kg ha⁻¹, no entanto em condições de sequeiro, onde há restrição hídrica, tem apresentado rendimentos superiores a 1.600 kg ha⁻¹ (CONAB, 2021). Por se tratar de cultivo de verão, não há custo com irrigação, promove as primeiras colheitas no Brasil, garantindo assim liquidez com melhores preços, além de apresentar grãos de qualidade, das classes trigo pão (alta força de glúten e estabilidade) (ALBRECHT et al., 2007).

O desenvolvimento do trigo pode ser subdividido em cinco fases segundo (ZADOKS et al., 1974):

1) Plântula – Ocorre após a germinação ou emergência da planta na superfície (estádio 1.13 de Zadoks, 5 a 7 dias) com o aparecimento das 3 primeiras folhas verdadeiras (12 a 16 dias – estágio 1.13 de Zadoks), esta fase coincide com a fixação das raízes seminais;

2) Perfilhamento – Aos 15 a 17 dias surgem (7 a 8 unidades – estádios 2.27 a 2.28 de Zadoks) e coincide com a abertura das folhas;

3) Alongamento – Tem-se início com o aparecimento do segundo nó (estádio 3.32 de Zadoks) e dura de 15 a 18 dias. Nessa fase também ocorre o aparecimento da folha bandeira (estádio 3.37 de Zadoks);

4) Emborrachamento – Durante o estágio do emborrachamento (estádio 4.43 de Zadoks), a espiga do trigo se desenvolve e se torna visível através da bainha sobre a haste e encerra-se com o surgimento das aristas (estádio 4.49 de Zadoks);

5) Espigamento – Ocorre com a emergência da espiga (estádio 5.51 de Zadoks) dando início à floração (estádio 6.61 de Zadoks) e ao enchimento dos grãos (estádio 7.70 de Zadoks); esta fase dura de 12 a 16 dias;

6) Maturação – Começa após a fertilização e inclui a estágio leitoso (estádios 7.71 a 7.79 de Zadoks), o pastoso (estádios 8.80 a 8.89 de Zadoks) enchimento de grão (transferência de nutrientes do caule e das folhas para o grão), essa fase dura cerca de 35 dias.

A cultura do trigo exige algumas condições edafoclimáticas para o seu bom desempenho, que geralmente variam conforme as fases supracitadas; na emergência, o solo deve apresentar temperatura em torno de 15°C e precipitação de 120 a 200 mm; no perfilhamento e início do espigamento, o solo deve apresentar temperaturas entre 8 a 18 °C e chuvas mensais de 40 mm; no espigamento, o solo deve apresentar temperaturas por volta de 18 °C e níveis de chuvas sempre inferiores de 60 mm/mês e sempre em condições sem ventos fortes e/ou geadas (WHITE, 2006).

É importante salientar que existem variações, nos genótipos de trigo, entre os estádios fenológicos de espiguetas terminal, emborrachamento, antese e maturação fisiológica (RODRIGUES et al., 2011). Não obstante, o trigo tem alta resistência a flutuações na disponibilidade de água durante o seu ciclo, mas é especialmente suscetível ao estresse hídrico no estágio de floração e no enchimento de grãos (ANWAAR et al., 2020).

A seleção de genótipos de trigo tolerantes à seca deve ser conduzida preferencialmente em condições de campo de uma maneira eficiente no pré-melhoramento e não somente na fase de plântulas, como descrito por Avramova et al. (2016) em trabalhos realizados com a cultura do milho, tornando capaz identificar indivíduos superiores ou linhagens elites para este fim em fases iniciais de desenvolvimento.

Portanto, a seleção para produtividade deve ser feita no ambiente representativo, como em condições de campo, considerando-se as principais características que influenciam o potencial produtivo e a qualidade dos grãos e sementes desta espécie.

2.3. Melhoramento genético de plantas visando tolerância à seca

A seca é um período em que a precipitação é pouco expressiva, durante o qual o conteúdo de água no solo é reduzido, afetando o desenvolvimento das plantas devido à disponibilidade insuficiente de água (SLETTE et al., 2019). Desenvolver e disponibilizar aos produtores genótipos produtivos e com características de tolerância a estresses abióticos, especialmente a deficiência hídrica, é um desafio contínuo para os programas de melhoramento genético de plantas, pois a seca é a maior fonte de instabilidade do rendimento de grãos das culturas (AHMED et al., 2019) e é considerada uma característica de difícil manipulação por apresentar caráter poligênico (FAHAD et al., 2017).

Além disso, para se obter sucesso no programa de melhoramento, é necessário o conhecimento da probabilidade de ocorrência de deficiência hídrica, bem como suas

características, como intensidade, duração e época de ocorrência, em função da fase fenológica da cultura, já que a resposta da planta ao estresse depende da interação genótipo x ambiente (FERRÃO et al., 2016).

Na obtenção de cultivares adaptadas ao déficit hídrico, dois princípios podem ser empregados: o melhoramento visando a tolerância à seca, e, alternativamente, o melhoramento para a eficiência no uso da água (EUA) (BASSETT, 2013). Uma planta tolerante à seca é capaz de resistir a condições adversas, sobreviver e deixar descendentes, ou seja, é uma planta capaz de manter suas funções sob deficiência hídrica. Genótipos tolerantes à seca, normalmente, possuem maior estabilidade de produção, mas, geralmente, tem menor potencial produtivo, sendo indicados, portanto, para sistemas de produção com menor nível tecnológico (SAINT PIERRE et al., 2012).

Por outro lado, a EUA é a razão entre a absorção e utilização da água, ou seja, é a capacidade que um genótipo tem de absorver a água do solo e transformá-la em biomassa, frutos ou grãos (FRITSCHÉ-NETO e BORÉM, 2011). Assim, o melhoramento para a EUA avalia a produção por unidade de água fornecida, de modo que quanto maior a quantidade de água disponível, maior a produtividade.

A ampliação da base genética, manutenção e caracterização de germoplasma, melhor compreensão da interação genótipo x ambiente e dos mecanismos de tolerância à seca, associados às estratégias de melhoramento convencional com a biotecnologia, fisiologia, engenharia genética, entre outras áreas correlatas, poderão acelerar a obtenção de resultados satisfatórios, minimizando, assim, os efeitos negativos da seca (FERRÃO et al., 2016).

O plantio de cultivares obtidas e/ou recomendadas para cada região, associado ao uso de outras práticas agronômicas, como o preparo de solo, adubação e calagem, manejo e conservação de solo, manejo de pragas e manejo da irrigação, poderão oferecer condições mais adequadas para as culturas sob estresse hídrico (EDREIRA et al., 2017), proporcionando, assim,

melhores produtividades e qualidade dos produtos, aumentando a sustentabilidade das atividades agrícolas.

Para a seleção de genótipos com tolerância ao déficit hídrico, é muito importante entender, principalmente, os mecanismos e o comportamento da planta sob estresse hídrico. Nesta condição, a planta desenvolve alterações morfológicas, fisiológicas, bioquímicas, anatômicas e em nível molecular que permite a identificação de genótipos mais adaptados ao estresse hídrico (BANERJEE et al., 2020).

Os melhoristas observam as características dos genótipos em diversas locais e condições de cultivo levando em consideração as características: área foliar, número de estômatos, espessamento das paredes celulares da folha, deposição de ceras epicuticulares e desenvolvimento do sistema radicular, senescência e maturidade das plantas, biomassa da cultura, peso de 1000 grãos, temperatura do dossel (AHMED et al., 2020); conteúdo total de água e turgor das células, fechamento dos estômatos, taxa de transpiração, trocas gasosas e a atividade fotossintética (KOSAR et al., 2015); pigmentos fotossintéticos (clorofila a e b), síntese de clorofila, processo de captação de CO₂, hábito verde sob situação de estresse e a atividade do cloroplasto (LIU et al., 2016); o processo de absorção e transporte de minerais, a partição de assimilados, a arquitetura e o rendimento da planta (LI et al., 2021).

Joshi et al. (2007) recomendaram alguns parâmetros essenciais que um melhorista pode simplesmente assimilar no programa de melhoramento de plantas para tolerância ao estresse hídrico, como: maior biomassa da cultura, maior peso de 1000 grãos, temperatura do dossel, maiores índices de vegetação (NDVI, NDRE e SAVI), maior condutância estomática e taxa fotossintética e manter a coloração verde sob situação de estresse hídrico. O rendimento da cultura e os componentes de rendimento também são importantes para avaliar a tolerância / resistência ao estresse hídrico (PATEL et al., 2019).

2.4. Estresse hídrico

A manutenção da produtividade, assim como da qualidade dos grãos depende das condições climáticas e dos genótipos, ou seja, interação genótipo x ambiente (ST-MARSEILLE et al., 2019). Dentre as alterações ambientais que prejudicam o desenvolvimento das culturas destacam-se as causadas pelo déficit hídrico, intensificadas nos últimos anos devido ao aquecimento global (SCHAUBERGER et al., 2019; PEÑA-GALLARDO et al., 2019). A seca é um fenômeno que ocorre em grandes extensões de áreas cultivadas (cerca de 60% das áreas cultivadas sem irrigação), causando perdas consideráveis no rendimento das culturas (AHMED et al., 2019).

A redução ou irregularidades nas precipitações nas fases críticas de desenvolvimento das culturas têm sido relatados, principalmente na região Centro-Oeste do Brasil, uma das maiores produtoras de grãos do país (CONAB, 2021), propiciando drásticas reduções na produtividade das culturas (HATFIELD, 2016). Neste cenário, a compreensão dos mecanismos utilizados pelas plantas para tolerar estresse hídrico é crucial para identificar cultivares de soja e de trigo com tolerância e/ou eficiência no uso de água, e conseqüentemente, diminuir as perdas de produtividade e de qualidade dos grãos dessas culturas.

A sobrevivência de plantas à seca depende de vários mecanismos operando simultaneamente. Contudo, existem três formas principais de lidar com a seca, também, consideradas adaptações ou estratégias naturais: (i) escape (ii) esquiva ou tolerância (iii) mecanismo de resistência. Na primeira, a planta completa os ciclos de vida antes da escassez de água. Na segunda, a planta promove seu desenvolvimento com a menor demanda de água, por exemplo, reduz a abertura estomática e diminui as taxas de transpiração. Na terceira, as plantas desenvolvem mecanismos ao nível das células contra as condições de déficit hídrico, através do desenvolvimento de antioxidantes que mantêm os ajustes osmóticos ao nível dos tecidos (AHMED et al., 2020).

Os ajustes morfofisiológicos (OUYANG et al., 2017), bioquímicos e metabólicos (MARČEK et al., 2019) para se adaptarem ao estresse hídrico, dentre outros exemplos, ocorrem pela redução da área foliar, a reorganização dos pigmentos fotossintetizantes, o desenvolvimento radicular, o controle estomático (HAWORTH et al., 2018), a eficiência do uso da água (EUA) e o crescimento das plantas (BLUM, 2016).

Diversos estudos têm evidenciado mecanismos que atuam na redução da perda de água nas plantas, dentre estes, destacam-se a síntese de ácido abscísico (ABA) no aumento do controle estomático (KUROMORI et al., 2018) e a redução da área foliar que reduz a superfície fotossintética (HARSH et al., 2016), diminuindo a taxa de transpiração, que restringe as trocas gasosas e inibe a atividade fotossintética (LIU et al., 2016), e tem como principal consequência a diminuição da produtividade.

Além dos mecanismos associados à manutenção do turgor celular, a capacidade de manter a performance fotossintética também é uma característica desejável para a seleção de genótipos de soja e trigo tolerantes ao estresse hídrico. A disponibilidade de água no solo é geralmente reduzida à medida que aumenta a temperatura e a capacidade da planta em conseguir tolerar essa redução na disponibilidade hídrica é crucial para a sua sobrevivência (HATFIELD, 2016). Nestas condições, o fechamento estomático é uma resposta que antecede qualquer comprometimento bioquímico da fotossíntese, particularmente por reduzir a fixação de CO₂ no ciclo de Calvin (SIDDIQUI et al., 2015).

No entanto, sob estresse hídrico juntamente com estresse térmico, devido ao aumento de temperatura, ocorrem maiores alterações na fixação de CO₂ em virtude da redução na solubilidade de CO₂ o que favorece a fixação de O₂ e a fotorrespiração (SICHER, 2015).

Adicionalmente, a permeabilidade das membranas dos tilacoides é aumentada, desestabilizando a cadeia transportadora de elétrons e as estruturas dos complexos proteicos, além de comprometer o gradiente de íons necessários para a fotossíntese (KALAJI et al., 2016).

O desbalanço energético promove, ainda, aumento da produção de compostos oxidantes causando danos em lipídeos e proteínas das membranas (NIU e XIANG, 2018). Plantas tolerantes a estas condições podem induzir a termoestabilidade das membranas, relacionada com a manutenção dos níveis de ácidos graxos e, por consequência, redução do extravasamento de eletrólitos (LARKINDALE e HUANG, 2004).

As plantas tolerantes à deficiência hídrica possuem, ainda, mecanismos enzimáticos na proteção contra espécies reativas de oxigênio (EROs), constituindo o sistema de defesa antioxidante. O mecanismo enzimático é constituído de enzimas importantes na rota de detoxificação de EROs, tais como a dismutase do superóxido, a catalase, a peroxidase do ascorbato e as peroxidases (HASANUZZAMAN et al., 2013).

Todos esses fatores desencadeiam efeitos em outros atributos que estão intimamente relacionados, no caso do trigo, com o rendimento do grão, o número de perfilhos, o número de grãos por espiga, o número de perfilhos férteis por planta, a massa de mil grãos, o comprimento do pedúnculo, a altura da planta, o comprimento da espiga, o número de grãos por espiga, a massa de grãos por espiga e a qualidade de grãos (BLUM, 2016).

Na soja o déficit hídrico provoca a redução na área foliar total, senescência das folhas, redução na produção de flores, abortamento floral, redução no número de vagens, decréscimo na produtividade e na qualidade de grãos (FIOREZE et al. 2011).

Estudos realizados por Majid et al. (2007) avaliaram os efeitos do estresse hídrico nas diferentes fases fenológicas do trigo, os autores indicaram que os estágios de pré-florescimento, florescimento e enchimento de grãos são os mais sensíveis e que, reduções na produção de grãos e no número de grãos por planta podem ser superiores a 50% quando a seca coincide com estes períodos. Daryanto et al. (2016) analisaram os dados de trabalhos publicados entre 1980 e 2015, e encontraram reduções de 21% no rendimento de trigo em escala global, devido ao estresse hídrico.

Em soja, perdas na produção de grãos de até 54% já foram registradas em decorrência do período de veranico (SIEBERS et al., 2015), quando seca e calor ocorrem concomitantemente no ambiente. De acordo com Sentelhas et al. (2015) o déficit hídrico é o principal fator limitante da produtividade da soja no Brasil, ocasionando, em média, uma perda em torno de 543 kg ha⁻¹.

Neste contexto, é evidente que a deficiência hídrica pode provocar alterações nas características das plantas, retardando o crescimento e desenvolvimento e, conseqüentemente, afetando a produtividade (GERGANOVA et al., 2016).

2.5. Sensoriamento remoto

O sensoriamento remoto (SR) caracteriza-se pela obtenção de informações de um objeto sem existir um contato físico com o mesmo. As primeiras medições por SR foram realizadas através de câmeras acopladas em aeronaves, foguetes e até pássaros. Atualmente, imagens de sensores remotos podem ser obtidas a partir de diversas plataformas, como satélites, aeronaves, veículos aéreos não tripulados (VANTs), máquinas agrícolas autopropelidas, etc (WEISS et al., 2020).

A detecção de diferenças na refletância, relacionadas à densidade da cobertura vegetal por meio do sensoriamento está sendo bastante estudada e identifica a intensidade com que cada material, seja um tipo de solo, de rocha ou de vegetação, reflete a radiação eletromagnética (BÉGUÉ et al., 2018).

Dados da refletância têm sido associados às características das plantas como o índice da área foliar, estimativa e qualidade de rendimento (BARMEIER, et al., 2017), monitoramento de estresse abiótico e biótico (MAHLEIN, 2015; CALERA et al., 2017) e avaliação do estágio fenológico (HAGHIGHATTALAB et al., 2016), auxiliando no diagnóstico, gerenciamento e subsidiando as tomadas de decisão no manejo agrícola.

Em contraste com as análises tradicionais, o sensoriamento remoto fornece uma estimativa rápida dos parâmetros bioquímicos e biofísicos da planta para grandes áreas em avaliações em condições de campo (MAIMAITIJIANG et al., 2017) ou mesmo em áreas menores, como em parcelas de experimentos. Desenvolvimentos recentes em sistemas aéreos não tripulados e sensores resultaram em soluções flexíveis e de baixo custo que podem fornecer imagens em alta resolução espacial, temporal e espectral.

Os veículos aéreos não tripulados equipados com vários sensores de imagem, pilotos automáticos e sistemas GPS, tornaram-se uma das ferramentas de sensoriamento remoto mais competitivas, oferecendo grandes possibilidades para a agricultura de precisão (SCHIRRMANN et al., 2016) e fenotipagem de alto rendimento (HAGHIGHATTALAB et al., 2016). Além disso, os VANTs podem complementar os dados obtidos por robôs baseados no solo, aumentando o rendimento e a frequência do monitoramento não destrutivo da planta (SHI et al., 2016).

2.5.1. Sensores

Em sensoriamento remoto, os sensores utilizados podem ser divididos em duas categorias: passivos ou ativos. Sensores passivos registram a energia eletromagnética refletida ou emitida pelo alvo, como a radiação solar refletida ou radiação termal emitida. Já os sensores ativos proporcionam fonte própria de energia eletromagnética, que dispara pulsos de laser sobre o alvo e identifica os respectivos retornos, tornando possível saber com precisão as coordenadas X, Y e Z de pontos no terreno (SOUZA et al., 2017).

Imagens de sensores remotos apresentam diferentes resoluções: espacial (dimensão, pixel), espectral (número e tamanho dos intervalos de comprimento de onda – bandas), temporal (intervalo entre imagens) e radiométrica (forma e precisão da medição da radiação

eletromagnética), sendo que o uso de técnicas de inteligência computacional facilita na utilização desses dados (ZHONG et al., 2018).

Na agricultura, tem sido bastante utilizados os sensores acoplados em veículos aéreos não tripulados ou drones, fornecendo dados com resoluções sem precedentes (MAES e STEPPE, 2019). Uma das possibilidades exclusivas dos VANTs é acoplar ao equipamento vários sensores ao mesmo tempo.

Em muitas áreas de pesquisa (por exemplo, avaliação do nível de nutrientes, detecção de doenças e estresse hídrico), o uso de câmeras termais pode ser complementar ao sensor multiespectral ou hiperespectral. Tanto a parte técnica ou de processamento, quanto a interpretação e processamento da fusão de dados, merecem maior prioridade de pesquisa (YAO et al., 2019).

Os VANTs possuem várias vantagens, dentre elas: (i) oferecer resolução centimétrica, (ii) combinar a altura do dossel 3D e informações ortofotográficas, (iii) fornecer dados multiangulares (principalmente de câmeras instantâneas), (iv) permitir dados hiperespectrais de alta qualidade e (v) a versatilidade dos sensores (AASEN et al., 2018). Em particular, para aplicações que requerem dados de alta resolução, térmicos ou hiperespectrais, como detecção precoce de estresse hídrico, detecção de plantas daninhas e detecção precoce de patógenos, os VANTs permanecerão ou se tornarão a plataforma padrão (MAES e STEPPE, 2019).

Quatro tipos de sensores cobrem quase todas as aplicações de sensoriamento remoto de VANT na pesquisa de agricultura de precisão. As câmeras comerciais RGB (vermelho-verde-azul) são baratas e têm uma alta resolução espacial, mas uma resolução espectral relativamente baixa (NIJLAND et al., 2014). Eles podem ser usados para calcular uma gama de índices de vegetação, bem como para gerar modelos digitais de elevação de alta resolução e mapas de altura de vegetação. Câmeras RGB modificadas são as mesmas câmeras nas quais o

filtro infravermelho próximo foi removido e substituído por um filtro vermelho, tornando a antiga faixa vermelha sensível ao espectro infravermelho próximo (NIR) (BERRA et al., 2017).

Um segundo tipo de câmeras, as multiespectrais possuem melhor resolução espectral e consistem em um conjunto de sensores com lentes diferentes, sendo cada sensor sensível em uma região espectral. As câmeras hiperespectrais cobrem todo o espectro (mais comumente) na região espectral de 400-1000 nm, em bandas relativamente estreitas (geralmente <10 nm) (ADÃO et al., 2017).

As câmeras térmicas, por fim, são normalmente câmeras de baixa resolução (resolução máxima de 640×512 pixels, ou 0,33 MP) com apenas uma banda medida com sensores de microbolômetro sensíveis no infravermelho de onda longa (7–12 μm) e podem ser usadas para extrair a temperatura do dossel (MAES et al., 2017).

Sensores multiespectrais possuem bandas em diferentes faixas do espectro eletromagnético, cobrindo a faixa do visível, infravermelho próximo, médio e termal. Permitem a extração das propriedades fisiológicas e geométricas da vegetação, bem como a estimativa precisa do conteúdo de clorofila, conteúdo de carotenoide, concentração de N, estresse abiótico e biótico e rendimento (MAIMAITIJIANG et al., 2017), tendo seu uso de grande relevância na agricultura.

2.5.2. Índices de vegetação

Os índices de vegetação (IVs) são formulações matemáticas elaboradas a partir de dados espectrais (reflectância) obtidos por sensores remotos (ATZBERGER, 2013), que utilizam em especial as faixas do visível e infravermelho próximo (NIR - Near Infrared). Dessa forma, o conhecimento do comportamento espectral dos objetos da superfície terrestre é importante para a aquisição e processamento dos dados obtidos pelos sensores (ZHANG et al., 2019).

A vegetação saudável reflete em todo o espectro visível, mas tem seu ápice na faixa da luz verde (500-600 nm), e cuja absorção é máxima nas faixas espectrais da luz azul (400-500 nm) e da luz vermelha (600-700 nm), principalmente por ser a faixa de reflectância e de absorção das clorofilas (PADOLFI et al., 2018), sendo mais importante na comparação com outros pigmentos. No NIR (750-1300 nm), dependendo do tipo de planta, a radiação solar é refletida numa proporção de 30 a 80% dos raios incidentes. Por outro lado, os comprimentos de ondas acima de 1300 nm e abaixo de 1950 nm são úteis na determinação do conteúdo hídrico das folhas (PEÑUELAS et al., 1997).

A refletância do dossel no NIR é fortemente dependente das propriedades estruturais (por exemplo, IAF), enquanto no visível é sensível às propriedades bioquímicas (por exemplo, clorofila) (ZARCO-TEJADA et al., 2001). Para reduzir esse efeito, muitos estudos recentes demonstraram que a quantidade de clorofila da folha pode ser estimada através da combinação de diferentes índices espectrais.

Dentre os IVs mais utilizados está o NDVI, devido à sua excelente responsividade a variações de vigor da vegetação. O NDVI foi proposto por Rouse et al. (1973) e é calculado usando imagens das bandas espectrais RED e NIR (Equação 1).

$$\text{NDVI} = \frac{(\text{NIR}-\text{RED})}{(\text{NIR}+\text{RED})} \quad (\text{Eq. 1})$$

Em que:

NIR - reflectância no infravermelho próximo;

Red - reflectância no vermelho.

Este IV é resultado de estudos que observaram a grande quantidade de absorção da luz vermelha advinda da radiação eletromagnética na vegetação, o que ocasiona uma baixa reflectância na faixa espectral correspondente ao vermelho. Por outro lado, comprovou-se que a vegetação refletia grande parte da energia relativa ao infravermelho. Assim, descoberto esse grande salto de reflectância entre as bandas R e NIR foi proposto o NDVI. Para sua análise, o

NDVI varia de -1 a 1 e, quanto mais próximo de 1 mais densa a vegetação e valores próximos a 0 quando não possuem cobertura vegetal.

A busca de índices cada vez mais refinados, promoveu o desenvolvimento de índices capazes de captar variações estruturais do dossel das culturas e sensíveis ao conteúdo de água foliar. O NDWI (Normalized Difference Water Index), desenvolvido por Gao (1996), é um índice de vegetação altamente correlacionado com o conteúdo de água presente na cobertura vegetal, permitindo monitorar mudanças na biomassa e avaliar o estresse hídrico da vegetação, sendo também pouco sensível aos efeitos da atmosfera. Segundo Szabó et al. (2016), esse índice requer o uso de uma banda situada na região do comprimento de onda do NIR e de uma banda situada no comprimento de onda do verde (Equação 2).

$$NDWI = \frac{(GREEN - NIR)}{(GREEN + NIR)} \quad (Eq. 2)$$

Em que:

NIR - reflectância no infravermelho próximo;

GREEN - reflectância no verde.

O GNDVI (Green Normalized Difference Vegetation Index) usa o verde visível em vez do vermelho visível e perto de infravermelho (DAUGHTRY et al., 2000). Ou seja, mede o espectro de verde de 540 até 570 nm em vez do espectro de vermelho (Equação 3). O índice é mais sensível à concentração de clorofila do que o NDVI. Juntamente com o NDRE (Normalized Difference Red Edge) (GITELSON e MERZLYAK, 1994), que utiliza as bandas do vermelho (RedEdge) (Equação 4) e do NIR, são índices bioquímicos responsivos e confiáveis para determinação de estresse em plantas.

$$GNDVI = \frac{(NIR - GREEN)}{(NIR + GREEN)} \quad (Eq. 3)$$

Em que:

NIR - reflectância no infravermelho próximo;

GREEN - reflectância no verde.

$$\text{NDRE} = \frac{(\text{NIR}-\text{RedEdge})}{(\text{NIR}+\text{RedEdge})} \quad (\text{Eq. 4})$$

Em que:

NIR - reflectância no infravermelho próximo;

RedEdge - reflectância no vermelho limítrofe.

Dentre os índices de razão simples, podem-se destacar na agricultura o GRVI (Green-Red Vegetation Index) (SRIPADA et al., 2006) (Equação 5) e o DVI Difference Vegetation Index) (TUCKER, 1979) (Equação 6). Valores DVI iguais a zero representam solo exposto, valores menores que zero, indicando água e valores maiores que zero indicando vegetação.

$$\text{GRVI} = \frac{\text{NIR}}{\text{GREEN}} \quad (\text{Eq. 5})$$

Em que:

NIR - reflectância no infravermelho próximo;

GREEN - reflectância no verde.

$$\text{DVI} = \text{NIR} - \text{RED} \quad (\text{Eq. 6})$$

Em que:

NIR - reflectância no infravermelho próximo;

RED - reflectância no vermelho.

O SAVI (Soil-Adjusted Vegetation Index) (RONDEAUX et al., 1996), foi criado visando amenizar o efeito de solo e baseia-se no princípio de que a curva de vegetação tende a aproximar-se da curva de solo para baixas densidades de vegetação, passando por uma mistura de respostas espectrais para densidades médias e quase nenhuma influência do solo para densidades altas de vegetação. O SAVI consiste na própria fórmula do NDVI, acrescida de uma constante L, que varia de 0 a 1, dependendo do grau da maior ou menor cobertura do solo, respectivamente (Equação 7).

$$\text{SAVI} = \frac{[(1+L)(\text{NIR}-\text{RED})]}{(\text{NIR}+\text{RED}+L)} \quad (\text{Eq. 7})$$

Em que:

NIR - reflectância no infravermelho próximo;

RED - reflectância no vermelho;

L = variável de ajuste do solo

Seguindo o mesmo princípio foi obtida a modificação do SAVI: OSAVI (Optimized SAVI) (STEVEN, 1998) (Equação 8); TCARI (Chlorophyll Absorption and Reflectance Index) (HABOUDANE et al., 2002) (Equação 9).

$$\text{OSAVI} = \frac{(\text{NIR}-\text{RED})}{(\text{NIR}+\text{RED}+0,16)} \quad (\text{Eq. 8})$$

Em que:

NIR - reflectância no infravermelho próximo;

RED - reflectância no vermelho;

$$\text{TCARI}=3[(\text{RedEdge}-\text{Red})-0.2(\text{RedEdge}-\text{Green})(\text{Red Edge}/\text{Red})] \quad (\text{Eq. 9})$$

Em que:

RedEdge – reflectância no vermelho limítrofe;

Green - reflectância no verde;

RED - reflectância no vermelho.

O PRI (Photochemical Physiological Reflectance Index) utiliza as bandas de reflectância nos comprimentos de onda do azul e do verde (Equação 10), sendo uma ferramenta útil na avaliação da eficiência fotossintética (GAMON et al., 1992), por ser uma variável sensível às alterações nos pigmentos de carotenoides das folhas.

Esses pigmentos são indicativos da eficiência do uso da luz fotossintética ou da taxa de dióxido de carbono armazenada pelas folhas por unidade de energia absorvida e exercem papel essencial na fotoproteção, pois liberam o excesso de energia antes que possa danificar os componentes celulares do organismo. A reação de clorofilas excitadas e o oxigênio molecular geram oxigênio singlete, que são altamente reativos, podendo provocar danos celulares, principalmente aos lipídios.

Os valores variam dentre -1 e 1 e os valores comuns para vegetação sem estresse ficam entre -0,2 a 0,2. O PRI tem sido utilizado com sucesso para a detecção de estresses nutricionais, hídricos e ainda, para a fenotipagem em plantas (SHRESTHA et al., 2012).

$$PRI = \frac{(BLUE-GREEN)}{(BLUE+GREEN)} \quad (\text{Eq. 10})$$

Em que:

BLUE – reflectância no azul;

GREEN - reflectância no verde.

2.6. Trocas gasosas e fluorescência da clorofila *a*

A fotossíntese é um processo que converte dióxido de carbono em compostos orgânicos, utilizando água e energia solar. Como parte desse processo, as plantas absorvem luz primariamente usando pigmentos, sendo a clorofila *a* uma das moléculas centrais, que absorvem a energia da luz do sol e utiliza essa energia para sintetizar carboidratos a partir de CO₂ e água (ROY et al., 2019).

A luz comporta-se como onda (comprimento e frequência de onda) e partícula, sendo que o comprimento de onda é a distância de duas cristas sucessivas (LAHIRI, 2011) e, a frequência, representa o número de ondas que passam por determinado observador em um certo intervalo de tempo (OUZOUNIS et al., 2015). Cada partícula recebe o nome de Fóton, e, cada Fóton é carregado internamente por uma energia denominada *Quantum* (plural = *quanta*), assim, quanto menor o comprimento de onda, maior a energia associada ao pacote energético *quanta*.

A luz absorvida e passível de ser utilizada nos processos fotossintéticos está compreendida no comprimento de onda de 400 a 700 nm (OUZOUNIS et al., 2015). A energia lumínica absorvida pelos complexos antena pode ser direcionada para os centros de reação por transmissão via ressonância, dissipada através de calor (conversão direta da energia em calor),

reemitida através de um fóton (fluorescência) ou desencadear a ocorrência de reações químicas (fotoquímica) (REITER et al., 2020).

Dessa forma, a fotossíntese, em plantas, engloba duas etapas de reações: uma chamada de reações fotoquímicas (conserva energia luminosa como ATP e NADPH, ao mesmo tempo que forma moléculas de O₂) e outra de reações bioquímicas ou de assimilação/fixação do carbono (ATP e NADPH consumidos para redução do CO₂ e formação de trioses fosfato, sacarose e outros derivados).

Nas reações fotoquímicas, a luz é capturada pelos pigmentos fotossintéticos presentes nas membranas dos tilacoides dos cloroplastos (principalmente, clorofila *a* e *b* - faixa do azul (430 nm) e vermelho (660 nm) e carotenoides - absorvem na faixa de 400 a 500 nm) e é direcionada aos centros de reação dos fotossistemas (KELLER et al., 2018). O centro de reação do Fotossistema II (PSII), é um oxidante forte e absorve a luz principalmente no comprimento de onda de 680 nm. O PSII é um complexo proteico, formado por duas subunidades denominadas D1 e D2, e ligados a ele estão aceptores de elétrons, que recebem e transportam os elétrons advindos da fotólise da água (McFARLANE et al., 2019). Para que ocorra a fotólise da água nesse complexo proteico são necessários íons de manganês e além dos elétrons, ocorre a liberação de íons de H⁺ no lúmen e de O₂ (JOHNSON et al., 2016).

Assim, o PSII oxida a água a O₂ no lume do tilacoide e, nesse processo, libera prótons no lume. O produto reduzido do PSII é a plasto-hidroquinona (PQH₂). O citocromo b₆f oxida moléculas de PQH₂ que foram reduzidas pelo PSII e entrega elétrons ao PSI por intermédio da proteína cúprica solúvel plastocianina. A oxidação da PQH₂ está acoplada à transferência de prótons do estroma para o lume, gerando uma força motriz de prótons. O centro de reação do Fotossistema I (PSI), captura energia lumínica na faixa do 700 nm e possui potencial de redução forte (JOHNSON et al., 2016). O PSI reduz o NADP⁺ a NADPH no estroma, pela ação da ferredoxina (Fd) e da flavoproteína ferredoxina-NADP⁺-reductase (FNR). A ATP-sintase produz

ATP à medida que prótons se difundem através do seu canal central do lume de volta ao estroma pelo gradiente eletroquímico (TAIZ et al., 2017).

Nas reações de assimilação do carbono, o ATP e o NADH gerados são usados para reduzir o CO₂ para formar trioses fosfatadas. As trioses fosfato servem como precursores da biossíntese do amido no cloroplasto ou fluem para o citosol, para a biossíntese de sacarose e outras reações metabólicas. A sacarose é carregada na seiva do floema e utilizada para crescimento ou biossíntese de polissacarídeos em outras partes da planta (STIRBET et al., 2019). Assim, o ATP e NADPH são utilizados no estroma dos cloroplastos na fase bioquímica da fotossíntese.

Esta etapa envolve, de uma forma geral, três processos a saber: carboxilação, redução e regeneração. Carboxilação - incorporação do CO₂ a molécula de ribulose-1,5-bifosfato (RuBP) catalisada pela rubisco (ribulose-1,5-bifosfato carboxilase oxidase), produzindo 3-fosfoglicerato; Redução – formação de trioses fosfato a partir da redução do 3-fosfoglicerato usando ATP e NADPH advindos da fase fotoquímica; e regeneração da molécula aceptor do CO₂, ribulose-1,5-bifosfato (SEMER et al., 2018). O CO₂ e O₂ competem nas reações de carboxilação e de oxigenação catalisadas pela rubisco. Estima-se que a sexta parte das trioses fosfatadas é utilizada para a síntese de amido e sacarose, o restante é utilizado na regeneração do RuBP (SHIMIZU et al., 2015).

Observa-se uma complexidade na transferência de energia e nas reações enzimáticas da fotossíntese e que fatores como o CO₂, a água e qualidade da luz são indispensáveis nesse processo. Sabe-se que o influxo de CO₂ ocorre necessariamente através dos estômatos no processo fotossintético ocorrendo também o efluxo de água, por meio da transpiração, sendo o movimento estomático o principal mecanismo de controle das trocas gasosas nas plantas superiores (ZAHRA et al., 2014).

Segundo Lawson e Vialet-Chabrand (2019), um dos impactos da deficiência hídrica nas plantas é a diminuição na abertura estomática, que evita a perda excessiva de água por meio da transpiração, mas isso também provoca a baixa disponibilidade de CO₂ no mesofilo, uma vez que a captação de CO₂ ocorre através da abertura estomática, reduzindo a taxa de fotossíntese.

A resposta estomática é provavelmente regulada por sinais da raiz em situações de estresse hídrico, principalmente, através do hormônio ácido abscísico (ABA), que é acumulado nestas condições (ZÖRB et al., 2018). Além de afetar a condutância estomática, o efeito osmótico da seca prejudica também a taxa fotossintética pela diminuição da área foliar, redução do conteúdo total de clorofila, limitação do transporte de elétrons nos cloroplastos, dentre outras alterações no metabolismo fotossintético, causando decréscimos na eficiência fotossintética e alterando os padrões de emissão de fluorescência (EL-HENDAWY et al., 2015).

A razão entre a fluorescência variável e a máxima (Fv/Fm), expressa o rendimento quântico do processo fotoquímico (neste fotossistema), indicando a eficiência relativa da captura de energia luminosa. Quando as plantas são expostas à luz, os centros de reação do PSII são progressivamente reduzidos. Dois parâmetros básicos descrevem a extinção da fluorescência da clorofila *a*: o *quenching* fotoquímico (qP) e o *quenching* não fotoquímico (NPQ) (BAKER, 2008).

O *quenching* fotoquímico (qP) representa a proporção de energia dos fótons capturada pelos centros de reação do PSII abertos e dissipada via cadeia transportadora de elétrons dos tilacoides (JUNEAU et al., 2005). Paralelamente, o *quenching* não fotoquímico (NPQ) representa a queda na fluorescência devido a fatores não fotoquímicos, especialmente devido a um aumento na perda de energia absorvida via dissipação térmica (JUNEAU et al., 2005), processo correlacionado com a formação de zeaxantina (BAKER, 2008).

Assim, as avaliações de trocas gasosas são importantes para determinar as taxas fotossintéticas, porém podem não ser eficientes para avaliar os efeitos deletérios nos cloroplastos; desta maneira, a avaliação da fluorescência da clorofila *a* revela o nível de excitação da energia que dirige a fotossíntese e fornece subsídios para estimar a inibição ou o dano no processo de transferência de elétrons do PSII (BAKER, 2008).

Essas avaliações simultâneas de fluorescência da clorofila *a* e de trocas gasosas das plantas permitem um melhor entendimento dos efeitos da restrição hídrica sobre o aparato fotossintético e são bastante úteis na seleção de plantas tolerantes a estresses abióticos (LIMA NETO et al., 2014).

Para a avaliação das variáveis de trocas gasosas (fotossíntese líquida, transpiração, condutância estomática e eficiência da carboxilação) e de fluorescência da clorofila *a* são utilizados sensores que permitem verificar o aparato fotossintético das plantas.

Dentre estes sensores, destacam-se os que utilizam a metodologia de análise da fluorescência de amplitude modulada, com mensuração de dados em distâncias de até 1m, permitindo a análise de uma ou poucas folhas, com o uso de analisador portátil de gás no infravermelho com fluorômetro acoplado, tais como: IRGA (mod. Li-6400XT, Li-COR, NE, USA) e Mini-PAM (WALS, GERMANY). Esses equipamentos emitem somente um pulso de saturação que é aplicado à folha, de modo a criar um “*pool*” de QA reduzido, que ao retornar ao seu estado energético basal, liberará sua energia na forma de fluorescência, como descrito pelas curvas de Kautsky e Hirsch (1931), relatado em Maxwell e Johnson (2000).

Por outro lado, é crescente a demanda por sensores fisiológicos não invasivos, não destrutivos e de alto rendimento que permitem a avaliação do potencial das culturas em acumular biomassa, potencial fotossintético e ainda, a eficiência no uso da água em condições de campo (ARAUS e CAIRNS, 2014; SHI et al., 2016).

A avaliação de genótipos de trigo quanto a capacidade de tolerância a estresse hídrico utilizando avaliações fisiológicas como taxa de fotossíntese, condutância estomática, teores de clorofila, NDVI e agrupando esses genótipos em tolerante ou sensível ao estresse hídrico é relatada por Nagar et al. (2015) e Banerjee et al. (2020). Outros parâmetros como NDVI e temperatura do dossel (KHADKA et al., 2020) e índice de susceptibilidade à seca (DSI) e o índice de resposta à seca (DRI) (MUNJAL E DHANDA 2016) são capazes de identificar planta de trigo sob condição de estresse hídrico.

Em soja, Giordani et al. (2019) relataram que características morfológicas, fisiológicas e componentes de rendimento devem serem avaliados simultaneamente para fazer inferências sobre a estabilidade de rendimento dessa cultura em condições de estresse hídrico, e que, devido à dificuldade em introduzir todos os mecanismos de tolerância à seca em um genótipo, programas de melhoramento precisam definir parâmetros de seleção de acordo com as condições regionais de seca.

2.7. Referências

AASEN, H.; HONKAVAARA, E.; LUCIEER, A.; ZARCO-TEJADA, P. J. Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. **Remote Sensing**, 2018, v. 10, n. 7, p. 1091, 2018. DOI: <https://doi.org/10.3390/rs10071091>

ADÃO, T.; HRUŠKA, J.; PÁDUA, L.; BESSA, J.; PERES, E.; MORAIS, R.; SOUSA, J. J. Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. **Remote Sensing**, v. 9, n. 11, 1110, 2017. DOI: <https://doi.org/10.3390/rs9111110>

AHMED, H. G. M-D.; SAJJAD, M.; LI, M.; AZMAT, M. A.; RIZWAN, M.; MAQSOOD, R. H.; KHAN, S. H. Selection Criteria for Drought-Tolerant Bread Wheat Genotypes at Seedling Stage. **Sustainability**, v. 11, n. 9, p. 1-17, 2019. DOI: [10.3390/su11092584](https://doi.org/10.3390/su11092584)

AHMED, H. G. M-D.; ZENG, Y.; YANG, X.; ANWAAR, H. A.; MANSHA, M. Z.; HANIF, C. M. S.; IKRAM, K.; ULLAH, A.; ALGHANEM, S. M. S. Conferring drought-tolerant wheat genotypes through morpho-physiological and chlorophyll indices at seedling stage. **Saudi Journal of Biological Sciences**, v. 27, n. 8, p. 2116-2123, 2020. DOI: <https://doi.org/10.1016/j.sjbs.2020.06.019>

ALBRECHT, J. C.; VIEIRA, E. A.; SILVA, M. S.; ANDRADE, J. M. V.; SCHEEREN, P. L.; TRINDADE, M. G.; SOBRINHO, J. S.; SOUSA, C. N. A.; REIS, W. P.; RIBEIRO JÚNIOR, W. Q.; FRONZA, V.; CARGNIN, A.; YAMANAKA, C. H. Adaptabilidade e estabilidade de genótipos de trigo irrigado no Cerrado do Brasil Central. **Pesquisa Agropecuária Brasileira**, v.42, n.12, 2007. DOI: <https://doi.org/10.1590/S0100-204X2007001200009>

ANDEREGG, J.; YU K.; AASEN, H.; WALTER, A.; LIEBISCH, F.; HUND, A. Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm. **Frontiers in Plant Science**, v.10, 2020. DOI: [10.3389/fpls.2019.01749](https://doi.org/10.3389/fpls.2019.01749)

ANDRADE-SANCHEZ, P.; GORE, M. A.; HEUN, J. T.; THORP, K. R.; CARMO-SILVA, A. E.; FRENCH, A. N.; SALVUCCI, M. E.; WHITE, J. W. Development and evaluation of a field-based high-throughput phenotyping platform. **Functional Plant Biology**, v. 41, n. 1, p. 68-79, 2014. DOI: <https://doi.org/10.1071/FP13126>

ANWAAR, H. A.; PERVEEN, R.; MANSHA, M. Z.; ABID, M.; SARWAR, M.; AATIF, H. M.; UMAR, U. U. D.; SAJID, M.; ASLAM, H. M. U.; ALAM, M. M.; RIZWAN, M.; IKRAM, R. M.; ALGHANEM, S. M. S.; RASHID, A.; KHAN, K. A. Assessment of grain yield indices in response to drought stress in wheat (*Triticum aestivum* L.). **Saudi Journal of Biological Sciences**, v. 27, n. 7, p. 1818-1823, 2020. DOI: <https://doi.org/10.1016/j.sjbs.2019.12.009>

ARAUS, J. L.; CAIRNS, J. E. Field high-throughput phenotyping: the new crop breeding frontier. **Trends Plant Science**, v. 19, p. 52-61, 2014. Doi: [10.1016/j.tplants.2013.09.008](https://doi.org/10.1016/j.tplants.2013.09.008)

ATZBERGER, C. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013. DOI: <https://doi.org/10.3390/rs5020949>

AVRAMOVA, V.; NAGEL, K. A.; ABDELGAVAD, H.; BUSTOA, D.; DUPLESSIS, M. FIORANI, F.; BEEMSTER, G. T. S. Screening for drought tolerance of maize hybrids by multi-

scale analysis of root and shoot traits at the seedling stage. **Journal of Experimental Botany**, v. 67, n. 8, p. 2453–2466, 2016. DOI: <https://doi.org/10.1093/jxb/erw055>

BAKER, N. R. Chlorophyll Fluorescence: A Probe of Photosynthesis In Vivo. **Annual Review of Plant Biology**, v. 59, p. 89-113, 2008. DOI: 10.1146/annurev.arplant.59.032607.092759

BANERJEE, K.; KRISHNAN, P.; DAS, B. Thermal imaging and multivariate techniques for characterizing and screening wheat genotypes under water stress condition. **Ecological Indicators**, v. 119, 106829, 2020. DOI: <https://doi.org/10.1016/j.ecolind.2020.106829>.

BARMEIER, G.; HOFER, K.; SCHMIDHALTER, U. Mid-season prediction of grain yield and protein content of spring barley cultivars using high-throughput spectral sensing. **European Journal of Agronomy**, v. 90, p. 108-116, 2017. DOI: <https://doi.org/10.1016/j.eja.2017.07.005>

BASSETT, C. L. Water use and drought response in cultivated and wild apples. In: VAHDATI, K.; LESLIE, C. **Abiotic Stress-Plant Responses and Applications in Agriculture**, p. 249-275, 2013.

BEEBE, S. E.; RAO, I. M.; DEVI, M. J.; POLANIA, J. Common bean, biodiversity, and multiple stresses: challenges of drought resistance in tropical soils. **Crop Pasture Science**, v. 65, p. 667–675, 2014. DOI: <https://doi.org/10.1071/cp13303>.

BÉGUÉ, A.; ARVOR, D.; BELLON, B.; BETBEDER, J.; ABELLEYRA, D.; FERRAZ, R. P. D.; LEBOURGEOIS, V.; LELONG, C.; SIMÕES, M.; VERÓN, S. R. Remote sensing and cropping practices: a review. **Remote Sensing**, v. 10, n. 1, p. 99, 2018. DOI: <https://doi.org/10.3390/rs10010099>

BERRA, E. F.; GAULTON, R.; BARR, S. Commercial Off-the-Shelf Digital Cameras on Unmanned Aerial Vehicles for Multitemporal Monitoring of Vegetation Reflectance and NDVI. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 9, p. 4878-4886, 2017. DOI: 10.1109/TGRS.2017.2655365

BLUM, A. Osmotic adjustment is a prime drought stress adaptive engine in support of plant production. **Plant, Cell and Environmental**, v. 40, n. 1, p. 1-7, 2016. DOI: 10.1111/pce.12800

BOSCHINI, A. P. M.; SILVA, C. L.; OLIVEIRA, C. A.; OLIVEIRA JÚNIOR, M. P.; MIRANDA, M. Z.; FAGIOLI, M. Aspectos quantitativos e qualitativos do grão de trigo

influenciados por nitrogênio e lâminas de água. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.15, p.450-457, 2011. DOI: <https://doi.org/10.1590/S1415-43662011000500003>

CALERA, A.; CAMPOS, I.; OSANN, A.; D'URSO, G.; MENENTI, M. Remote Sensing for Crop Water Management: From ET Modelling to Services for the End Users. **Sensors**, v. 17, n. 5, p. 1104, 2017. DOI: <https://doi.org/10.3390/s17051104>

CEREZINI, P.; FAGOTTI, D. S. L.; PÍPOLO, A. E.; HUNGRIA, M.; NOGUEIRA, M. A. Water restriction and physiological traits in soybean genotypes contrasting for nitrogen fixation drought tolerance. **Scientia Agricola**, v.74, n. 2, p. 110-117, 2017. DOI: <https://doi.org/10.1590/1678-992x-2016-0462>

CHACON, D. P.; BARAJAS, E. M.; ESTEVA, A. G.; DELGADO, R. L.; SHIBATA, J. K.; VALDIVIA, C. B. P. Biomass remobilization in two common bean (*Phaseolus vulgaris*) cultivars under water restriction. **South African Journal of Botany**, v. 112, p. 79-88, 2017. DOI: <https://doi.org/10.1016/j.sajb.2017.05.015>.

CONAB. Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira de grãos. Safra 2020/2021, n. 3 - Terceiro levantamento, p. 1-86, 2021. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos>. Acesso em: 11 de janeiro de 2021.

CONAB. Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira de grãos. Safra 2021/2022, n. 4 - Quarto levantamento, p. 1-25, 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos>. Acesso em: 05 de fevereiro de 2022.

DARYANTO, S.; WANG, L.; JACINTHE, P. A. Global Synthesis of Drought Effects on Maize and Wheat Production. **PLoS ONE**, v. 11, n. 5, e0156362, 2016. DOI: [10.1371/journal.pone.0156362](https://doi.org/10.1371/journal.pone.0156362)

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, p. 229-239, 2000. DOI: [10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)

EDREIRA, J. I. R.; MOURTZINIS, S.; CONLEY, S. P.; ROTH, A. C.; CIAMPITTI, I. A.; LICHT, M. A.; KANDEL, H.; KYVERYGA, P. M.; LINDSEY, L. E.; MUELLER, D. S.; NAEVE, S. L.; NAFZIGER, E.; SPECHT, J. E.; STANLEY, J.; STATON, M. J.; GRASSINI, P. Assessing causes of yield gaps in agricultural areas with diversity in climate and soils.

Agricultural and Forest Meteorology, v. 247, p. 270-280, 2017. DOI: <https://doi.org/10.1016/j.agrformet.2017.07.010>

EL-HENDAWY, S.; AL-SUHAIBANI, N.; SALEM, A.; UR REHMAN, S.; SCHMIDHALTER, U. Spectral reflectance indices as a rapid nondestructive phenotyping tool for estimating different morphophysiological traits of contrasting spring wheat germplasm under arid conditions. **Turkish Journal of Agriculture and Forestry**, v. 39, p. 572-587, 2015. DOI: 10.3906 / tar-1406-164

ENGELS, C.; RODRIGUES, F. A.; FERREIRA, A. O.; INAGAKI, T. M.; NEPOMUCENO, A. L. Drought Effects on Soybean Cultivation - A Review. **Annual Research & Review in Biology**, v. 16, n. 1, p. 1-13, 2017. DOI: 10.9734/ARRB/2017/35232

FAHAD, S.; BAJWA, A. A.; NAZIR, U.; ANJUM, S. A.; FAROOQ, A.; ZOHAIB, A.; SADIA, S.; NASIM, W.; ADKINS, S.; SAUD, S.; IHSAN, M. Z.; ALHARBY, H.; WU, C.; WANG, D.; HUANG, J. Crop Production under Drought and Heat Stress: Plant Responses and Management Options. **Frontiers in Plant Science**, v. 8, n. 29, p. 1-17, 2017. DOI: <https://doi.org/10.3389/fpls.2017.01147>

FEHR, W.R., CAVINESS, C.E. **Stages of soybean development**. Ames: Iowa State University, 1977. 12p. (Special Report, 80). DOI: <https://lib.dr.iastate.edu/specialreports/87>

FERRÃO, R. G.; MOREIRA, S. O.; FERRÃO, M. A. G.; RIVA, E. M.; ARANTES, L. O.; COSTA, A. F. S.; CARVALHO, O. L. P. T.; GALVÊAS, P. A. O. Genética e melhoramento: desenvolvimento e recomendação de cultivares com tolerância à seca para o Espírito Santo. **Incap em Revista**, v. 6 e 7, n. 4, p. 51-71, 2016.

FIGLIORINI, S. L.; PIVETTA, L. G.; FANO, A.; MACHADO, F. R.; GUIMARÃES, V. F. Comportamento de genótipos de soja submetidos a déficit hídrico intenso em casa de vegetação. **Revista Ceres**, v. 58, n. 3, p. 342-349, 2011. DOI: <https://www.redalyc.org/pdf/3052/305226801005>

FITA, A.; RODRÍGUEZ-BURRUEZO, A.; BOSCAIU, M.; PROHENS, J.; VICENTE, O. Breeding and domesticating crops adapted to drought and salinity: A new paradigm for increasing food production. **Frontiers in Plant Science**, v. 6, n. 12, p. 978, 2015. DOI: 10.3389/fpls.2015.00978

FREITAS, M. C. M. A cultura da soja no brasil: o crescimento da produção brasileira e o surgimento de uma nova fronteira agrícola. **Enciclopédia Biosfera**, v. 7, n. 12, p. 1-12, 2011.

FRITSCHÉ-NETO, R.; BORÉM, A. **Melhoramento de plantas para condições de estresses abióticos**. Viçosa: Editora UFV, 2011.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)

GAMON, J. A.; PENUÉLAS, J.; FIELD, C.B.A. Narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, n. 1, p. 35-44, 1992. DOI: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)

GERGANOVA, M.; POPOVA, A. V.; STANOEVA, D.; VELITCHKOVA, M. Tomato plants acclimate better to elevated temperature and high light than to treatment with each factor separately. **Plant Physiology and Biochemistry**, v. 104, p. 234-241, 2016. DOI: [10.1016/j.plaphy.2016.03.030](https://doi.org/10.1016/j.plaphy.2016.03.030)

GIORDANI, W.; GONÇALVES, L. S. A.; MORAES, L. A. C.; FERREIRA, L. C.; NEUMAIER, N.; FARIAS, J. R. B.; NEPOMUCENO, A. L.; OLIVEIRA, M. C. N.; MERTZ-HENNING, L. M. Identification of agronomical and morphological traits contributing to drought stress tolerance in soybean. **Australian Journal of Crop Science**, v. 13, n. 1, p. 35-44, 2019. DOI: [10.21475/ajcs.19.13.01.p1109](https://doi.org/10.21475/ajcs.19.13.01.p1109)

GITELSON, A.; MERZLYAK, M.N. Quantitative estimation of chlorophyll-using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology**, v. 22, n.3, p. 247-252, 1994. DOI: [10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)

GOMES, D. P.; ROCHA, V. S.; ROCHA, J. R. A. S. C.; SOUZA, M. A.; PEREIRA, O. L. Progresso temporal do brusone do trigo em função do inóculo primário, da aplicação de fungicida e da resistência dos genótipos. **Summa Phytopathologica**, v.45, n.1, p.50-58, 2019. DOI: [10.1590/0100-5405/187354](https://doi.org/10.1590/0100-5405/187354)

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrowband vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, p. 416-426, 2002. DOI: [doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)

HAGHIGHATTALAB, A.; GONZALEZ, L.; MONDAL, S.; SINGH, D.; SCHINSTOCK, D.; RUTKOSKI, J.; ORTIZ-MONASTERIO, I.; SINGH, R.; GOODIN, D.; POLAND, J. Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries. **Plant methods**, v. 12, n. 1, p. 35, 2016. DOI: 10.1186/s13007-016-0134-6

HARSH, A.; SHARMA, Y. K.; JOSHI, U.; RAMPURIA, S.; SINGH, G.; KUMAR, S.; SHARMA, R. Effect of short-term heat stress on total sugars, proline and some antioxidant enzymes in moth bean (*Vigna aconitifolia*). **Annals of Agricultural Sciences**, v. 61, n. 1, p. 57-64, 2016. DOI: <https://doi.org/10.1016/j.aoas.2016.02.001>

HASANUZZAMAN, M.; NAHAR, K.; ALAM, M. M.; ROYCHOWDHURY, R.; FUJITA M. Physiological, biochemical, and molecular mechanisms of heat stress tolerance in plants. **International Journal of Molecular Sciences**, v.14, n. 5, p. 9643-9684, 2013. DOI: 10.3390/ijms14059643

HATFIELD, J. L. Increased temperatures have dramatic effects on growth and grain yield of three maize hybrids. **Agricultural & Environmental Letters**, v. 1, n. 1, 2016. DOI: <https://doi.org/10.2134/aerl2015.10.0006>

HAWORTH, M.; MARINO, G.; BRUNETTI, C.; KILLI, D.; CARLO, A.; CENTRITTO, M. The Impact of Heat Stress and Water Deficit on the Photosynthetic and Stomatal Physiology of Olive (*Olea europaea* L.) — A Case Study of the 2017 Heat Wave. **Plants**, v. 7, n. 4, p. 76, 2018. DOI: 10.3390/plants7040076

JOSHI, A. K.; MISHRA, B.; CHATRATH, R.; FERRARA, G. O.; SINGH, R. P. Wheat improvement in India: present status, emerging challenges and future prospects. **Euphytica**, v. 157, n. 3, p. 431–446, 2007. DOI: <https://doi.org/10.1007/s10681-007-9385-7>.

JUNEAU, P.; GREEN, B. R.; HARRISON, P. J. Simulation of Pulse-Amplitude-Modulated (PAM) fluorescence: Limitations of some PAM-parameters in studying environmental stress effects. **Photosynthetica**, v. 43, p. 75-83, 2005. DOI: <https://doi.org/10.1007/s11099-005-5083-7>

KALAJI, H. M.; JAJOO, A.; OUKARROUM, A.; BRESTIC, M.; ZIVCAK, M.; SAMBORSKA, I. A.; LADLE, R. J. Chlorophyll a fluorescence as a tool to monitor physiological status of plants under abiotic stress conditions. **Acta physiologia and plantarum**, v. 38, n. 4, p. 102, 2016. DOI: 10.1007/s11738-016-2113-y

- KAUTSKY, H.; HIRSCH, A. Neue Versuche zur Kohlensäureassimilation. **Naturwissenschaften**, v. 19, p. 964-964, 1931. DOI: <https://doi.org/10.1007/BF01516164>
- KELLER, B.; VASS, I.; MATSUBARA, S.; PAUL, K.; JEDMOWSKI, C.; PIERUSCHKA, R.; NEDBAL, L.; RASCHER, U.; MULLER, O. Maximum fluorescence and electron transport kinetics determined by light-induced fluorescence transients (LIFT) for photosynthesis phenotyping. **Photosynthesis Research**, v. 140, p. 221-233, 2018. DOI: <https://doi.org/10.1007/s11120-018-0594-9>
- KHADKA, K.; EARL, H. J.; RAIZADA, M. N.; NAVABI, A. A Physio-Morphological Trait-Based Approach for Breeding Drought Tolerant Wheat. **Frontiers in Plant Science**, v. 11, 2020. DOI: [10.3389/fpls.2020.00715](https://doi.org/10.3389/fpls.2020.00715)
- KOSAR, F.; AKRAM, N. A.; ASHRAF, M. Exogenously-applied 5-aminolevulinic acid modulates some key physiological characteristics and antioxidative defense system in spring wheat (*Triticum aestivum* L.) seedlings under water stress. **South African Journal of Botany**, v. 96, p. 71-77, 2015. DOI: <https://doi.org/10.1016/j.sajb.2014.10.015>.
- KUROMORI, T.; SEO, M.; SHINOZAKI, K. ABA transport and plant water stress responses. **Trends in plant science**, v. 23, n. 6, p. 513-522, 2018. DOI: <https://doi.org/10.1016/j.tplants.2018.04.001>
- LAHIRI, M. Wave-particle duality and polarization properties of light in single-photon interference experiments. **Physical Review A**, v. 83, p. 1-3, 2011. DOI: <https://doi.org/10.1103/PhysRevA.83.045803>
- LARKINDALE J., HUANG B. Thermotolerance and antioxidant systems in *Agrostis stolonifera*: involvement of salicylic acid, abscisic acid, calcium, hydrogen peroxide, and ethylene. **Journal Plant Physiology**, v. 161, n. 4, p. 405–413, 2004. DOI: [doi: 10.1078/0176-1617-01239](https://doi.org/10.1078/0176-1617-01239)
- LAWSON, T.; VIALET-CHABRAND, S. Speedy stomata, photosynthesis and plant water use efficiency. **New Phytologist**, v. 221, n. 1, p. 93-98, 2019. DOI: <https://doi.org/10.1111/nph.15330>
- LESK, C.; ROWHANI, P.; RAMANKUTTY, N. Influence of extreme weather disasters on global crop production. **Nature**, v. 7, n. 529, p. 84-87, 2016. DOI: [10.1038/nature16467](https://doi.org/10.1038/nature16467)

LI, P.; MA, B.; PALTA, J. A.; DING, T.; CHENG, Z.; LV, G.; XIONG, X. Wheat breeding highlights drought tolerance while ignores the advantages of drought avoidance: A meta-analysis. **European Journal of Agronomy**, v. 122, 126196, 2021. DOI: <https://doi.org/10.1016/j.eja.2020.126196>

LIMA NETO, M. C.; LOBO, A. K.; MARTINS, M. O.; FONTENELE, A. V.; SILVEIRA J. A. Dissipation of excess photosynthetic energy contributes to salinity tolerance: a comparative study of salt-tolerant *Ricinus communis* and salt-sensitive *Jatropha curcas*. **Journal of Plant Physiology**, v. 171, n. 1, p. 23-30, 2014. DOI: [10.1016/j.jplph.2013.09.002](https://doi.org/10.1016/j.jplph.2013.09.002).

LIU, E. K.; MEI, X. R.; YAN, C. R.; GONG, D. Z.; ZHANG, Y. O. Effects of water stress on photosynthetic characteristics, dry matter translocation and WUE in two winter wheat genotypes. **Agricultural Water Management**, v. 167, n.3, p. 75-85, 2016. DOI: <https://doi.org/10.1016/j.agwat.2015.12.026>

MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science**, v. 24, n. 2, p. 152-164, 2019. DOI: <https://doi.org/10.1016/j.tplants.2018.11.007>

MAES, W. H.; HUETE, A. H.; STEPPE, K. Optimizing the Processing of UAV-Based Thermal Imagery. **Remote Sensing**, 2017, v. 9, n. 5, p. 476, 2017. DOI: <https://doi.org/10.3390/rs9050476>

MAHLEIN, A. K. Plant disease detection by imaging sensors – parallels and specific demands for precision agriculture and plant phenotyping. **Plant Disease**, v. 100, n. 2, p. 241-251, 2015. DOI: <https://doi.org/10.1094/PDIS-03-15-0340-FE>

MAIMAITIJIANG, M.; GHULAM, A.; SIDIKE, P.; HARTLING, S.; MAIMAITIYIMING, M.; PETERSON, K.; SHAVERS, R.; FISHMAN, J.; PETERSON, J.; KADAM, S.; BURKEN, J.; FRITSCHI, F. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 134, p. 43-58, 2017. DOI: <https://doi.org/10.1016/j.isprsjprs.2017.10.011>.

MAJID, S. A.; ASGHAR, R.; MURTAZA, G. Yield stability analysis conferring adaptation of wheat to pre-and post-anthesis drought conditions. **Pakistan Journal of Botany**, v. 39, p. 1623-1637, 2007.

MARIANI, L.; FERRANTE, A. Agronomic Management for Enhancing Plant Tolerance to Abiotic Stresses - Drought, Salinity, Hypoxia, and Lodging. **Horticulturae**, v.3, n.52, 2017. Doi: 10.3390/horticulturae3040052

MARČEK, T.; HAMOW, K.; VÉGH, B.; JANDA, T.; DARKO, E. Metabolic response to drought in six winter wheat genotypes. **PLoS ONE**, v.14, n. 2, p. 1-23, 2019. DOI: <https://doi.org/10.1371/journal.pone.0212411>

MATESE, A.; TOSCANO, P.; DI GENNARO, S. F.; GENESIO, L.; VACCARI, F. P.; PRIMICERIO, J.; BELLI, C.; ZALDEI, A.; BIANCONI, R.; GIOLI, B. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. **Remote Sensing**, v. 7, n. 3, p. 2971-2990, 2015. DOI:<https://doi.org/10.3390/rs70302971>

MAXWELL, K.; JOHNSON, G.N. Chlorophyll fluorescence - a practical guide. **Journal of Experimental Botany**, v. 51, n. 345, p. 659-668, 2000. DOI: <https://doi.org/10.1093/jexbot/51.345.659>

McFARLANE, C. R.; SHAHA, N. R.; KABASAKALA, B. V.; BECHEVERRIAA, B.; COTTONA, C. A. R.; BUBECKA, D.; MURRAY, J. W. Structural basis of light-induced redox regulation in the Calvin-Benson cycle in cyanobacteria. **PNAS**, v. 116, n. 42, p. 20984-20990, 2019. DOI: <https://doi.org/10.1073/pnas.1906722116>

MEENA, R.P.; VENKATESH, K.; SENDHIL, R.; KHOBA, R.; SHARMA, R.K.; TRIPATHI, S.C.; SINGH, G.P. Identification of water use efficient wheat genotypes with high yield for regions of depleting water resources in India. **Agricultural Water Management**, v. 223, 105709, 2019. DOI: <https://doi.org/10.1016/j.agwat.2019.105709>.

MUNJAL, R.; DHANDA, S. S. Assessment of Drought Resistance in Indian Wheat Cultivars for Morpho-Physiological Traits. **Ekin Journal of Crop Breeding and Genetics**, v. 2, n. 1, p. 74-81, 2016. DOI: <https://dergipark.org.tr/en/pub/ekinjournal/issue/22787/243195>

NAGAR, S., SINGH, V.P., ARORA, A.; DHAKAR, R.; RAMAKRISHNAN, S. Assessment of terminal heat tolerance ability of wheat genotypes based on physiological traits using multivariate analysis. **Acta Physiologiae Plantarum**, v. 37, n. 257, 2015. DOI: <https://doi.org/10.1007/s11738-015-2017-2>

NAOE, A.M.L.; PELUZIO, J.M.; SOUSA, J.P. Estresse ambiental na cultura da soja. **Revista Integralização Universitária**, v. 12, n. 16, p. 71-80, 2017.

NIJLAND, W.; JONG, R.; JONG, S. M.; WULDER, M. A.; BATER, C. W.; COOPS, N. C. Monitoring plant condition and phenology using infrared sensitive consumer grade digital câmeras. **Agricultural and Forest Meteorology**, v. 184, p. 98-106, 2014. DOI: <https://doi.org/10.1016/j.agrformet.2013.09.007>

NIU, Y.; XIANG, Y. An overview of biomembrane functions in plant responses to high-temperature stress. **Frontiers in plant science**, v. 9, p. 915, 2018. DOI: <https://doi.org/10.3389/fpls.2018.00915>

OUYANG, W.; STRUIK, P. C.; YIN, X.; YANG, J. Stomatal conductance, mesophyll conductance, and transpiration efficiency in relation to leaf anatomy in rice and wheat genotypes under drought, **Journal of Experimental Botany**, v. 68, n. 18, p. 5191–5205, 2017. DOI: <https://doi.org/10.1093/jxb/erx314>

OUZOUNIS, T.; ROSENQVIST, E.; CARL-OTTO OTTOSEN, C. O. Spectral Effects of Artificial Light on Plant Physiology and Secondary Metabolism: A Review. **Horticultural Science**, v. 50, n. 8, p. 1128-1135, 2015. DOI: <https://doi.org/10.21273/HORTSCI.50.8.1128>

PADOLFI, A. S.; RAMALDES, G. P.; SANTOS, O. L. Análise de índice de vegetação através de imagens obtidas por Vant. **Revista Científica da FAESA**, v. 14, n. 1, p. 145-165, 2018. DOI: 10.5008/1809.7367.143

PATEL, J.M.; PATEL, A. S.; PATEL, C. R.; MAMRUTHA, H. M.; PRADEEP, S.; PACHCHIGAR, K. P. Evaluation of Selection Indices in Screening Durum Wheat Genotypes Combining Drought Tolerance and High Yield Potential. **International Journal of Current Microbiology and Applied Sciences**, v. 8, n. 4, p. 1165-1178, 2019. DOI: <https://doi.org/10.20546/ijemas.2019.804.134>

PEÑA-GALLARDO, M.; VICENTE-SERRANO S. M.; QUIRINGB, S.; SVOBODA, M.; HANNAFORDD, M.; HANNAFORDD, J.; TOMAS-BURGUERA, M.; MARTÍN-HERNÁNDEZA, N.; DOMÍNGUEZ-CASTRO, F.; KENAWY, E. A. Response of crop yield to different timescales of drought in the United States: Spatio-temporal patterns and climatic and environmental driver. **Agricultural and Forst Meteoroly**, v. 264, p. 40-55, 2019. DOI: <https://doi.org/10.1016/j.agrformet.2018.09.019>

PEÑUELAS, J.; PIÑOL, J.; OGAYA, R.; FILELLA, I. Estimation of plant water concentration by the reflectance water index WI (R900/R970). **International Journal of Remote Sensing**, v. 18, n. 13, p. 2869-2875, 1997. DOI: <http://dx.doi.org/10.1080/014311697217396>

PEREIRA, J. F.; CUNHA, G. R.; MORESCO, E. R. Improved drought tolerance in wheat is required to unlock the production potential of the Brazilian Cerrado. **Crop Breeding and Applied Biotechnology**, v. 19, n.2, p. 217-225, 2019. DOI: <https://doi.org/10.1590/1984-70332019v19n2r30>

QIU, R. C.; WEI, S.; ZHANG, M.; SUN, H.; LI, H.; LIU, G.; LI, M. Sensors for measuring plant phenotyping: A review. **International Journal of Agricultural and Biological Engineering**, v. 11, n. 2, p. 1–17, 2018. DOI: [10.25165/j.ijabe.20181102.2696](https://doi.org/10.25165/j.ijabe.20181102.2696)

RAY, D. K.; GERBER, J. S.; MACDONALD, G. K.; WEST, P. C. Climate variation explains a third of global crop yield variability. **Nature Comunitations**, v. 22, p. 1-9, 2015. DOI: [10.1038/ncomms6989](https://doi.org/10.1038/ncomms6989)

REITER, B.; VAMVAKA, E.; MARINO, G.; KLEINE, T.; JAHNS, P.; BOLLE, C.; LEISTER, D.; RÜHLE, T. The Arabidopsis Protein CGL20 Is Required for Plastid 50S Ribosome Biogenesis. **Plant Physiology**, v. 182, n. 3, p. 1222-1238, 2020. DOI: <https://doi.org/10.1104/pp.19.01502>

RIGO, A. A. DAHMER, A. M.; STEFFENS, C.; STEFFENS, J.; CARRÃO-PANIZZI, M. C. Characterization of soybean cultivars genetically improved for human consumption. **International Journal of Food Engineering**, v. 1, n. 1, p. 1-7, 2015. DOI: <https://doi.org/10.18178/ijfe.1.1.1-7>

RITCHIE, S. W.; HANWAY, J. J.; THOMPSON, H. E.; BENSON, G. O. How a soybean plant develops. Ames: Iowa State University of Science and Technology, 1977. 20 p. (Special Report, 53)

RODRIGUES, O.; HAAS, J. C.; COSTENARO, E. R. Manejo de trigo para alta produtividade II: caracterização ontogenética. **Revista Plantio Direto**, v. 125, p. 10-13, 2011.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, p. 95-107, 1996. DOI: [10.1016/0034-4257\(95\)00186-](https://doi.org/10.1016/0034-4257(95)00186-7)

ROSA, A.; MIRANDA, A. G. G.; LEWANDOSKI, C. F.; SANTOS, R. F. Produção de biodiesel de óleo cru refinado e óleo de fritura de soja. **Acta Iguazu**, v.9, n.2, p. 59-66, 2020. DOI: <https://doi.org/10.48075/actaiguaz.v9i2.23267>

ROUSE, J.W.; J. R. HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **Proc 3rd ERTS Symp 1**, p. 48–62, 1973.

ROY, N.; SUZUKI, N.; TERASHIMA, C.; FUJISHIMA, A. Recent Improvements in the Production of Solar Fuels: From CO₂ Reduction to Water Splitting and Artificial Photosynthesis. *Bulletin of the Chemical Society of Japan*, v. 92, n. 1, p. 178-192, 2019. DOI: <https://doi.org/10.1246/bcsj.20180250>

SAINT PIERRE, C. S.; CROSSA, J. L.; BONNETT, D.; YAMAGUCHI-SHINOZAKI, K.; REYNOLDS, M. P. Phenotyping transgenic wheat for drought resistance. **Journal of Experimental Botany**, v. 63, n. 5, p. 1799-1808, 2012. DOI: <https://doi.org/10.1093/jxb/err385>

SCHAUBERGER, B.; ROLINSKI, S.; SCHAPHOFF, S.; MULLER, C. Global historical soybean and wheat yield loss estimates from ozone pollution considering water and temperature as modifying effects. **Agricultural and Forest Meteorology**, v. 265, p. 1-15, 2019. DOI: <https://doi.org/10.1016/j.agrformet.2018.11.004>

SCHIRRMANN, M.; GIEBEL, A.; GLEINIGER, F.; PFLANZ, M.; LENTSCHKE, J.; DAMMER, K. H. Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery. **Remote Sensing**, v. 8, n. 9, p. 706-714, 2016. DOI: <https://doi.org/10.3390/rs8090706>

SEMER, J.; ŠTROCH, M.; ŠPUNDA, V.; NAVRÁTIL, M. Partitioning of absorbed light energy within photosystem II in barley can be affected by chloroplast movement. **Journal of Photochemistry and Photobiology B: Biology**, v. 186, p. 98-106, 2018. DOI: <https://doi.org/10.1016/j.jphotobiol.2018.06.019>

SENTELHAS, P. C.; BATTISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A.; NENDEL, C. The soybean yield gap in Brazil - magnitude, causes and possible solutions for a sustainable production. **Journal of Agricultural Science**, v. 153, n. 8, p. 1394–1411, 2015. DOI: <https://doi.org/10.1017/S0021859615000313>

SHI, Y. Y.; THOMASSON, J. A.; MURRAY, S. C.; PUGH, N. A.; ROONEY, W. L.; SHAFIAN, S.; RAJAN, N.; ROUZE, G.; MORGAN, C. L. S.; NEELY, H. L.; RANA, A.; BAGAVATHIANNAN, M. V.; HENRICKSON, J.; BOWDEN, E.; VALASEK, J.;

OLSENHOLLER, J.; BISHOP, M. P.; SHERIDAN, R.; PUTMAN, E. B.; POPESCU, S.; BURKS, T.; COPE, D.; IBRAHIM, A.; MCCUTCHEN, B. F.; BALTENSBERGER, D. D.; AVANT, R. V.; VIDRINE, M.; YANG, C. H. Unmanned aerial vehicles for high-throughput phenotyping and agronomic research. **PLoS ONE**, v. 11, n. 7, e0159781, 2016. DOI: <https://doi.org/10.1371/journal.pone.0159781>

SHIMIZU, R.; DEMPO, Y.; NAKAYAMA, Y.; NAKAMURA, S.; BAMBIA, T.; FUKUSAKI, E.; FUKUI, T. New Insight into the Role of the Calvin Cycle: Reutilization of CO₂ Emitted through Sugar Degradation. **Scientific Reports**, v. 5, p. 1-12, 2015. DOI: 10.1038/srep11617

SHRESTHA, S.; BRUECK, H.; ASCH, F. Chlorophyll index, photochemical reflectance index and chlorophyll fluorescence measurements of rice leaves supplied with different N levels. **Journal of Photochemistry and Photobiology B: Biology**, v.113, p.7-13, 2012. DOI: 10.1016/j.jphotobiol.2012.04.008

SICHER, R. C. Temperature shift experiments suggest that metabolic impairment and enhanced rates of photorespiration decrease organic acid levels in soybean leaflets exposed to supra-optimal growth temperatures. **Metabolites**, v.5, n. 3, p. 443-454, 2015. DOI: 10.3390/metabo5030443

SIDDIQUI, M. H.; MUTAHHAR Y.; AL-KHAISHANY A.; MOHAMMED, A.; ALQUTAMI, A.; MOHAMED H.; WHAIBI, A.; GROVER, A.; HAYSSAM, M.; MONA, S.; AL-WAHIBI, A.; BUKHARI, N. A. Response of different genotypes of Faba Bean plant to drought stress. **International Journal of Molecular Sciences**, v. 16, n. 5, n. 3, p. 10214- 10227, 2015. DOI: 10.3390/ijms160510214

SIEBERS, M. H.; YENDREK, C. R.; DRAG, D.; LOCKE, A. M.; ACOSTA, L. R.; LEAKEY, A. D. B.; AINSWORTH, E. A.; BERNACCHI, C. J.; ORT, D. R. Heat waves imposed during early pod development in soybean (*Glycine max*) cause significant yield loss despite a rapid recovery from oxidative stress. **Global Change Biology**, v. 21, n. 8, p. 3114-3125, 2015. DOI: 10.1111/gcb.12935

SLETTE, I. J.; POST, A. K.; AWAD, M.; EVEN, T.; PUNZALAN, A.; WILLIAMS, S.; SMITH, M. D.; KNAPP, A. K. How ecologists define drought, and why we should do better. **Global Change Biology**, v. 25, n. 10, p. 3193–3200, 2019. DOI: <https://doi.org/10.1111/gcb.14747>

SOARES, G. F.; RIBEIRO JÚNIOR, W. Q.; PEREIRA, L. F.; LIMA, C. A.; SOARES, D. S.; MULLER, O.; RASCHER, U.; RAMOS, M. L. G. Characterization of wheat genotypes for drought tolerance and water use efficiency. **Scientia Agricola**, v. 78, n. 5, e20190304, 2021. DOI: <https://doi.org/10.1590/1678-992x-2019-0304>

SOBEJANO-PAZ, V.; MIKKELSEN, T. N.; BAUM, A.; MO, X.; LIU, S.; KÖPPL, C. J.; JOHNSON, M. S.; GULYAS, L.; GARCÍA, M. Hyperspectral and Thermal Sensing of Stomatal Conductance, Transpiration, and Photosynthesis for Soybean and Maize under Drought. **Remote Sensing**, v. 12, n. 19, 2020. DOI: <https://doi.org/10.3390/rs12193182>

SOUZA, H. B.; BAILO, F. H. R.; NEVES, D. C. Using passive and active multispectral sensors on the correlation with the phenological indices of cotton. **Engenharia Agrícola**, v. 37, n. 4, p. 782-789, 2017. DOI: <https://doi.org/10.1590/1809-4430-eng.agric.v37n4p782-789/2017>

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER, A. D. Aerial Color Infrared Photography for Determining Early In-season Nitrogen Requirements in Corn. **Agronomy Journal**, v. 98, p. 968-977, 2006. DOI: <https://doi.org/10.2134/agronj2005.0200>

STEVEN, M. D. The sensitivity of the OSAVI vegetation index to Observational Parameters. **Remote Sensing of Environment**, v. 63, p. 49-60, 1998. DOI: [https://doi.org/10.1016/S0034-4257\(97\)00114-4](https://doi.org/10.1016/S0034-4257(97)00114-4)

STIRBET, A.; LAZÁR, D.; PAPAGEORGIOU, G. C. Chapter 5 - Chlorophyll a Fluorescence in Cyanobacteria: Relation to Photosynthesis. **Cyanobacteria**, p. 79-130, 2019. DOI: <https://doi.org/10.1016/B978-0-12-814667-5.00005-2>.

ST-MARSEILLE, A., BOURGEOIS, G., BRODEUR, J., MIMÉE, B. Simulating the impacts of climate change on soybean cyst nematode and the distribution of soybean. **Agricultural and Forest Meteorology**, v. 264, p. 178-187, 2019. DOI: <https://doi.org/10.1016/j.agrformet.2018.10.008>

SZABÓ, S.; GÁCSI, Z.; BALÁZS, B. Specific features of NDVI, NDWI and MNDWI as reflected in land cover categories. **Landscape and Environment**, v. 10, n. 3-4, p. 194–202, 2016. DOI: 10.21120/LE/10/3-4/13

TAIZ, L.; ZEIGER, E.; MOLLER, I. M.; MURPHY, A. **Fisiologia e desenvolvimento vegetal**. 6. ed., Porto Alegre: Artmed, 2017. 858 p.

TRACE – Traicing origins of food. **Molecular Biology Database**. Disponível em: <http://www.bats.ch/trace/?file5=coreforms/taxonomy.php&record_number=21>. Acesso em: 12 de janeiro de 2021.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

WANG, L.; LIN, F.; LI, L.; LI, W.; YAN, Z.; LUAN, W.; PIAO, R.; GUAN, Y.; NING, X.; ZHU, L.; MA, Y.; DONG, Z.; ZHANG, H.; ZHANG, Y.; GUAN, R.; LI, Y.; LIU, Z.; CHANG, R.; QIU, L. Genetic diversity center of cultivated soybean (*Glycine max*) in China—New insight and evidence for the diversity center of Chinese cultivated soybean. **Journal of Integrative Agriculture**, v. 15, n. 11, p. 2481-248, 2016. DOI: [https://doi.org/10.1016/S2095-3119\(15\)61289-8](https://doi.org/10.1016/S2095-3119(15)61289-8)

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, 111402, 2020. DOI: <https://doi.org/10.1016/j.rse.2019.111402>

WHITE, J. W. From genome to wheat: Emerging opportunities for modeling wheat growth and development. **European Journal of Agronomy**, v. 25, n. 2, p. 79-88, 2006. DOI: <https://doi.org/10.1016/j.eja.2006.04.002>

YANG M.; HASSAN, M. A.; XU, K.; ZHENG, C.; RASHEED, A.; ZHANG, Y.; JIN, X.; XIA, X.; XIAO, Y.; HE, Z. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, 2020. DOI: [10.3389/fpls.2020.00927](https://doi.org/10.3389/fpls.2020.00927)

YAO, H.; QIN, R.; CHEN, X. Unmanned Aerial Vehicle for Remote Sensing Applications - A Review. **Remote Sensing**, v. 11, n. 12, p. 1443, 2019. DOI: <https://doi.org/10.3390/rs11121443>

ZADOKS, J. C.; CHANG, T. T.; KONZAK, C. F. A decimal code for the growth stages of cereals. **Weed Research**, v. 14, n. 6, p. 415-421, 1974. DOI: <https://doi.org/10.1111/j.1365-3180.1974.tb01084.x>

ZAHRA, J.; NAZIM, H.; CAI, S.; HAN, Y.; WU, D.; ZHANG, B.; HAIDER, S. I.; ZHANG, G. The influence of salinity on cell ultrastructures and photosynthetic apparatus of barley

genotypes differing in salt stress tolerance. **Acta Physiol Plant**, v. 36, p. 1261-1269, 2014. DOI: <https://doi.org/10.1007/s11738-014-1506-z>

ZARCO-TEJADA, P. J.; MILLER, J. R.; NOLAND, T. L.; MOHAMMED, G. H.; SAMPSON, P. H. Scaling-up and model inversion methods with narrow-band optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data. **IEEE Transactions on Geoscience Remote Sensing**, v. 39, n. 7, p. 1491-1507, 2001. DOI: <http://dx.doi.org/10.1109/36.934080>

ZHANG, B.; CHEN, Z.; PENG, D.; BENEDIKTSSON, J. A.; LIU, B.; ZOU, L.; LI, J.; PLAZA, A. Remotely sensed big data: evolution in model development for information extraction [point of view]. **Proceedings of the IEEE**, v. 107, n. 12, p. 2294-2301, 2019. Doi: [10.1109/JPROC.2019.2948454](https://doi.org/10.1109/JPROC.2019.2948454)

ZHAO, W.; LIU, L.; SHEN, Q.; YANG, J.; HAN, X.; TIAN, F.; WU, J. Effects of Water Stress on Photosynthesis, Yield, and Water Use Efficiency in Winter Wheat. **Water**, v. 12, n. 8, p. 1-19, 2020. DOI: <https://doi.org/10.3390/w12082127>

ZHONG, Y.; MA, A.; ONG, Y. S.; ZHU, Z.; ZHANG, L. Computational intelligence in optical remote sensing image processing. **Applied Soft Computing**, v. 64, p. 75-93, 2018. DOI: <https://doi.org/10.1016/j.asoc.2017.11.045>.

ZÖRB, C.; LUDEWIG, U.; HAWKESFORD, M. J. Perspective on Wheat Yield and Quality with Reduced Nitrogen Supply. **Trends in Plant Science**, v. 23, n. 11, p. 1029-1037, 2018. DOI: <https://doi.org/10.1016/j.tplants.2018.08.012>.

Capítulo 1. Respostas fisiológicas, rendimento e qualidade de grãos de cultivares de soja submetidos a estresse hídrico no Cerrado

Resumo: Dentre os fatores do clima que mais influenciam a produção agrícola, podem se destacar as precipitações pluviométricas irregulares, como as encontradas no bioma Cerrado, que impactam negativamente as culturas. Metodologias de fenotipagem não destrutivas e automatizadas, são bastante convenientes para tornar o processo de seleção de plantas rápido e eficiente para este fator limitante. O objetivo deste trabalho foi avaliar o efeito do estresse hídrico na fisiologia, no rendimento e na qualidade de grãos de cultivares de soja, no Cerrado. Foi utilizado o delineamento experimental em blocos ao acaso, em esquema de parcelas subdivididas. As parcelas foram compostas de seis cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR) e as subparcelas, por quatro regimes hídricos (31, 44, 64 e 100% da reposição da evapotranspiração da cultura - ETc), com três repetições. Os experimentos foram conduzidos no período de maio a setembro de 2018 e de 2019. Utilizou-se um sistema de irrigação com uma barra com aspersores com diferentes vazões, criando-se um gradiente de água. Foram avaliadas as trocas gasosas, os índices de vegetação, os componentes de produção e a qualidade dos grãos. As condições de estresse hídrico afetaram negativamente as trocas gasosas, os índices de vegetação, o rendimento e a composição química dos grãos, mas em graus diferentes nas cultivares. As cultivares BRS 7280RR e NA 5909RG possuem estabilidade produtiva e apresentaram maior tolerância a seca. Índices de vegetação são variáveis responsivas ao estresse hídrico e são correlacionados com as características morfofisiológicas em soja, podendo prever a produtividade e ser utilizada como ferramenta de seleção.

Palavras-chave: *Glycine max*, índices de vegetação, trocas gasosas, tolerância à seca, automação.

1.1. Introdução

A soja é a principal cultura cultivada no Cerrado com efeitos econômicos e sociais positivos para a região e é considerada uma importante e barata fonte de proteína, óleo e energia (PEREIRA et al., 2021), o que é importante considerando o desafio de alimentar cerca de nove bilhões pessoas até 2050 (FAO, 2009). Entre os fatores ambientais, a seca é o que mais afeta a produtividade das culturas (SCHEELBEEK et al., 2018; SOARES et al., 2021). A ausência de cultivares tolerantes à seca e a ocorrência de períodos secos no Cerrado brasileiro (CATTELAN e DALL'AGNOL, 2018), é uma das principais causas de perdas de produtividade e qualidade de grãos da soja (LOPES e GUIMARÃES, 2016). Portanto, é essencial encontrar cultivares tolerantes à seca (ALEXANDER, 2016). Plataformas para fenotipagem de seca em campo têm sido utilizadas com sucesso no Cerrado (PEREIRA et al., 2021).

A seleção de cultivares tolerantes à seca pode ser feita por meio de uma combinação de variáveis, a saber: eficiência no uso da água (MEENA et al., 2019), componentes de produtividade (FRIED et al., 2019), índices vegetativos e fisiológicos (BUEZO et al., 2019; BRAGA et al., 2021; ZHOU et al., 2021), que podem ser correlacionadas com o rendimento e qualidade de grãos (WIJEWARDANA et al., 2019).

O uso de índices de vegetação (VI) avaliados por sensores multiespectrais acoplados a drones que fornecem medições de comprimento de onda no visível (VIS; ~ 400-700 nm) e infravermelho próximo (NIR; ~ 700- 1.200 nm) é um método rápido e não destrutivo que permite avaliação em qualquer estágio de desenvolvimento da planta para avaliar fatores abióticos e bióticos (QIU et al., 2018), e se correlaciona com o rendimento (SILVA et al., 2020a). Os índices de vegetação são uma opção para a seleção de genótipos em comparação com ferramentas invasivas e destrutivas em estudos de interação planta-ambiente. Esses índices estão relacionados à estrutura da planta, pigmentos e eficiência fotossintética e podem fornecer

informações valiosas sobre os efeitos do estresse hídrico na fisiologia da planta (SOBEAJANO-PAZ et al., 2020).

O índice de vegetação de diferença normalizada (NDVI) é comumente o mais utilizado e está relacionado a características estruturais (SILVA et al., 2020a). No entanto, o uso de múltiplos índices mostrou poder preditivo (ZHAO et al., 2020), incluindo VIs associados a características estruturais da planta (por exemplo, índice de vegetação ajustado ao solo otimizado (OSAVI)); alterações de pigmento (por exemplo, a absorvância da clorofila convertida em índice de refletância (TCARI) e a razão entre TCARI e OSAVI, que reduz o efeito devido a mudanças na área foliar e refletância do solo). Além disso, a atividade fotoquímica (PRI) responde a mudanças estruturais, conteúdo de pigmento, exposição do solo, efeitos de iluminação e ângulo do dossel da planta (BALLESTER et al., 2018). O uso de índices de vegetação pode ser usado para selecionar cultivares de soja tolerantes à seca como obtido por (CRUSIOL et al., 2017).

Além disso, Maimaitiyiming et al. (2017) obtiveram fortes relações entre índices de vegetação e parâmetros fisiológicos da planta. Os índices de vegetação podem ser usados para selecionar cultivares de soja tolerantes à seca e outras culturas no nível foliar e por meio de plataformas VANT (veículo aéreo não tripulado) (ZARCO-TEJADA et al., 2012; ZARCO-TEJADA et al., 2013; PERES e CANCELLIERE, 2021). Adicionalmente, sensores térmicos acoplados a VANT podem medir outras características importantes relacionadas à temperatura do dossel, mostrando pequenas diferenças na temperatura da folha associada ao estresse hídrico (ZARCO-TEJADA et al., 2012; SANTESTEBAN et al., 2017).

As características morfofisiológicas também são indicadores do desempenho da planta sob estresse hídrico, como a redução na taxa de fotossíntese, na altura da planta, número de folhas, vagens e peso seco da parte aérea (GURUMURTHY et al., 2019; PEREIRA et al.,

2021). Além disso, a qualidade do grão é alterada, aumentando o teor de proteína e diminuindo o teor de óleo (SILVA et al., 2020b; PEREIRA et al., 2021).

Portanto, é importante a obtenção de genótipos adaptados a condições estressantes com capacidade de tolerar períodos de estiagem sem grandes prejuízos à produtividade (BRAGA et al., 2021). A hipótese desse trabalho é que a redução da disponibilidade hídrica diminui a produtividade e qualidade dos grãos e que variáveis não destrutivas são importantes para a seleção de genótipos de soja sob estresse hídrico.

O objetivo deste trabalho foi validar sensores de alto rendimento e avaliações morfofisiológicas como ferramentas para a seleção de cultivares de soja para produtividade e qualidade de grãos sob estresse hídrico.

1.2. Material e Métodos

O experimento foi conduzido em Planaltina, DF, Brasil (15°35'30'' S e 47°42'30'' W e altitude de 1006 m). O clima da região é do tipo Aw (Köppen-Geiger) - Tropical, com chuvas concentradas no verão (outubro a abril) e um período seco bem definido durante a estação de inverno (maio a setembro), com precipitação média anual que varia de 1200 a 1500 mm. Os dados climatológicos da área foram coletados nos anos de 2018 e 2019, em uma estação meteorológica próxima ao experimento (Figura 1).

O trabalho foi realizado entre maio e setembro por coincidir com o período de estiagem na região, o que possibilita o controle do fornecimento de água à cultura. O solo é classificado como Latossolo Vermelho distroférrico (SANTOS et al., 2018), e a análise de solo realizada antes da implantação do experimento apresentou as seguintes características físico-químicas, na profundidade de 0 a 20 cm: pH (CaCl₂) de 5,7; P de 11 mg dm⁻³; K de 186 mg dm⁻³; Ca de 5,77 cmol_c dm⁻³; Mg de 1,83 cmol_c dm⁻³; Al de 0,02 cmol_c dm⁻³ e granulometria de 46, 10 e 44 dag kg⁻¹ de argila, silte e areia, respectivamente.

A curva de retenção de água do solo ajustado pelo modelo de Van Genuchten (1980) apresentou os seguintes parâmetros: conteúdo de água residual (θ_s) $0,0839 \text{ cm}^3 \text{ cm}^{-3}$, conteúdo de água na saturação (θ_s) $0,5500 \text{ cm}^3 \text{ cm}^{-3}$ e os parâmetros α ($1,892 \text{ kPa}^{-1}$) e n (1,2390). A umidade na capacidade de campo foi de $0,3423 \text{ cm}^3 \text{ cm}^{-3}$. O parâmetro α está associado ao inverso do valor do potencial da matriz em que o ar entra no maior poro do solo, representando, portanto, uma unidade de pressão. O parâmetro n é um índice da distribuição do tamanho dos poros, portanto relacionado à inclinação da curva característica solo-água.

O delineamento experimental foi em blocos ao acaso em esquema de parcelas subdivididas, com três repetições. As parcelas foram compostas pelas cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR) e as subparcelas corresponderam a quatro regimes hídricos (RH). As cultivares BRS 5980IPRO, BRS 7180IPRO, BRS 7280RR e BRS 7380RR foram desenvolvidas pelo programa de melhoramento genético da Embrapa e foram selecionadas para este trabalho por apresentarem alto rendimento, estabilidade de produção, sanidade e ampla adaptabilidade às diversas regiões produtoras de grãos do Cerrado brasileiro. As cultivares NA 5909RG e M 6410IPRO também são recomendadas para a região.

Em 2018, 160,1 mm, 274,68 mm, 420,55 mm e 634,35 mm foram aplicados durante o ciclo da cultura, correspondendo a RH1, RH2, RH3 e RH4, respectivamente. Em 2019, 164, 179 mm, 237,45 mm, 343,15 mm e 531,43 mm foram aplicados correspondendo a RH1, RH2, RH3 e RH4, respectivamente. Em 2018 e 2019, os regimes hídricos utilizados foram equivalentes a 31%, 44%, 64% e 100% da reposição da evapotranspiração da cultura (ETc). Em ambos os anos, a precipitação foi incluída nos cálculos de água aplicada.

O histórico dos últimos 3 anos de cultivo da área experimental é de soja sob diferentes regimes hídricos no inverno e pousio no verão. A área foi dessecada com glifosato na dose de $1440 \text{ g.e.a ha}^{-1}$ aos 20 dias antes da semeadura. As sementes de soja foram previamente

inoculadas com *Bradyrhizobium japonicum* (estirpe SEMIA 5080) na dose de 100 mL para 50 kg de sementes. A semeadura foi realizada mecanicamente no dia 02 de junho de 2018 e em 23 de maio de 2019, sob plantio direto, utilizando-se 16 sementes por metro. Na adubação de base utilizaram-se 300 kg ha⁻¹ de adubo formulado 04-30-16 (N, P₂O₅, K₂O).

Como tratamentos fitossanitários, visando o controle de vaquinha (*Diabrotica speciosa*) foram realizadas aplicações do inseticida tiametoxam + lambda-cialotrina nas doses de 14,1 g + 10,6 g ha⁻¹ aos 10 e aos 20 dias após a emergência da soja (DAE), no ano de 2018, e aos 12 e 24 DAE, no ano de 2019. A aplicação do herbicida glifosato na dose de 720 g.e.a ha⁻¹ foi realizada aos 18 DAE para controle das plantas daninhas, em ambos os anos.

Em ambos os experimentos, aplicou-se a mesma lâmina de água nos primeiros 35 dias após a emergência (DAE), com a reposição média de 140 mm de água, para se obter um estande de plantas homogêneo. Após esse período, foi adotada a metodologia de “line source” (HANKS et al., 1976), modificada pela introdução de uma barra de irrigação (JAYME-OLIVEIRA et al., 2017). Utilizaram-se aspersores com vazão decrescente do meio para a borda da barra, a fim de produzir um gradiente de déficit hídrico. Os regimes hídricos (RH) foram obtidos através da barra de irrigação (IrrigaBrasil modelo 36/42), de 20 m de largura em cada lado, conectada a um TurboMaq 75/GB autopropulsor, com velocidade ajustável de acordo com a lâmina de água a ser aplicada.

Cada unidade experimental foi composta por um genótipo, formado por 36 linhas de cultivo, com 5,0 m de comprimento, em espaçamento de 0,5 m. Cada regime hídrico (RH) constituiu uma subunidade experimental de 5,0 m de comprimento, formada por 8 linhas, com espaçamento de 0,50 m, com a área útil constituída pelas duas linhas centrais, descartando-se as bordaduras e 0,5 m de cada extremidade, ou seja, 4 m² (Figura 2).

As irrigações de nível mais alto foram realizadas conforme descrito no programa de monitoramento de irrigação no Cerrado (EMBRAPA, 2011), isto é, através da reposição da

evapotranspiração, utilizando-se indicadores agrometeorológicos da região, tipo de solo e data de emergência total das plantas. O programa estima a evapotranspiração de referência com base na equação proposta por Penman-Monteith (ALLEN et al., 1998). A frequência de irrigação foi realizada aproximadamente a cada 5 dias, de acordo com as condições climáticas e a fase fenológica da cultura. Para quantificar a quantidade de água aplicada, em cada irrigação, foram montadas duas fileiras de coletores paralelos à linha de irrigação para medir o volume de água aplicada.

Para a caracterização das variáveis fisiológicas, foram avaliados aos 70 DAE, na fase fenológica R5.1, a assimilação líquida de CO₂ (*A*), condutância estomática (*g_s*) e a taxa de transpiração (*E*). Essa avaliação foi realizada das 8:30 às 12:30, sob uma irradiância de 1200 μmol de fótons m⁻² s⁻¹ e concentração externa de CO₂ (*C_a*) de 400 μmol mol⁻¹ de ar, umidade relativa estava entre 65 e 70%, a temperatura entre 20 e 25 °C (noite/dia) com um equipamento de sistema de troca de gás de fluxo aberto portátil (LI-6400xt LI-COR Inc., Lincoln, NE).

O rendimento quântico máximo do fotossistema II (*F_v/F_m*), foram medidos usando um fluorômetro portátil modulado acoplado a IRGA. As avaliações foram realizadas em folhas adaptadas ao escuro, por pelo menos 3 h, e a avaliação foi realizada após as 22h30, de modo que os centros de reação estivessem totalmente abertos (todos os aceptores primários de elétrons oxidados) com mínima perda de calor. Nesta condição, foi possível estimar a fluorescência inicial (*F₀*), fluorescência máxima (*F_m*) e rendimento quântico máximo do fotossistema II [*F_v/F_m* = (*F₀*-*F_m*)/*F_m*] (GENTY et al., 1989).

Em cada subparcela, foram feitas três avaliações para quantificar as trocas gasosas. As avaliações foram realizadas na folha central do trifólio superior totalmente expandido, com folhas de soja adaptadas à luz e fisiologicamente maduras.

Os índices de vegetação (*IV*) foram determinados na fase R5.1 usando uma câmera multiespectral modelo Micasense RedEdge acoplada em um veículo aéreo não tripulado

(VANT) de asas rotativas. Esta câmera captura imagens em cinco diferentes bandas espectrais, denominadas blue (intervalo: 465-485 nm; Largura: 20 nm), green (intervalo: 550-570 nm; largura: 20 nm), red (intervalo: 663-673nm; largura:10 nm), red edge (intervalo: 712-722nm; largura: 10nm), near infra-red (NIR) (intervalo: 820-860 nm; largura: 40 nm), com resolução óptica de 1280 x 960 pixels e imagens gravadas em RAW12 bits (MICASENSE, 2020). O voo foi realizado a 45 m de altura, às 10:00 h.

Os mapas de reflectância foram calculados a partir da geração dos mosaicos no software Pix4D Mapper (v5.4.6, Pix4D, Lausanne, Suíça), com base nas imagens do painel (MicaSense, modelo RP04 CRP) de calibração antes e após cada voo, além da captura da radiação no momento de cada imagem. Posteriormente, as imagens foram processadas no software R usando o pacote raster (HIJMANS, 2014) e extraídos os índices de vegetação (Tabela 1).

Na colheita da soja, avaliou-se o rendimento de grãos (RG) na área útil de cada subunidade experimental, e na área útil foram colhidas, ao acaso, dez plantas representativas, para a avaliação da altura de inserção da primeira vagem (A1), a altura de plantas (AP), o diâmetro do coleto (DC) e o número total de vagens por planta (VP). Destas plantas foram utilizadas 200 vagens, aleatoriamente, e foi determinado o número de grãos por vagem (GV) e a massa de 1000 grãos (MMG). O rendimento de grãos e a massa de 1000 grãos foram expressos, padronizando-se o teor de água dos grãos para 13% em base úmida.

A eficiência no uso de água (EUA) foi calculada através da relação entre rendimento de grãos e demanda hídrica da cultura (HATFIELD et al., 2001). A eficiência intrínseca do uso da água (iEUA) foi calculada pela razão entre a assimilação líquida de CO₂ e a condutância estomática (A/g_s). Posteriormente, foram analisados a qualidade dos grãos (teor de proteínas e óleos) e o peso do hectolitro (PH). As porcentagens de proteína e o óleo foram determinadas em grãos inteiros e sem impurezas pela técnica de Espectroscopia de Reflexão no Infravermelho

Próximo (NIRS), de acordo com Heil (2010). As análises foram realizadas no Laboratório de Análises Químicas da EMBRAPA Soja, por espectroscopia de infravermelho próximo com transformada de Fourier (FT-NIR, modelo Antaris II, ThermoFisher Scientific Waltham, Ma, EUA), utilizando amostras de 30 g de grãos e utilizando uma esfera integradora com leituras que variam de 1100 a 2500 nm. Os modelos matemáticos desenvolvidos pela EMBRAPA Soja em 2011–2012 foram usados para prever o teor de proteína, incluindo 180 padrões, coeficiente de correlação (r) = 0,97 e erro quadrático médio de calibração (RMSEC) = 0,64. Para o teor de óleo: 170 padrões, r = 0,98 e RMSEC = 0,45.

Os dados foram submetidos à análise de variância multivariada conjunta, por safra, baseado em decomposição em valores singulares (SVD). Os resíduos foram testados quanto à normalidade multivariada pelo teste de Shapiro-Wilk (VILLASENOR-ALVA e GONZALEZ-ESTRADA 2009) e a homogeneidade de matrizes de covariância pelo teste M de Box (BOX, 1949). Em dois anos, as médias dos tratamentos (combinações de cultivares e níveis de regime hídrico) foram analisadas graficamente em um *biplot* baseado na decomposição de valores singulares (GABRIEL, 1971). A análise de correlação de Pearson (teste t, $p < 0,05$) foi realizada com os resíduos. As médias das variáveis nos dois anos de cultivo e, o comportamento das principais variáveis, foram apresentados na tabela de média e nos modelos de regressão. As análises estatísticas foram realizadas utilizando-se o software R v3.6.1 (R Core Team, 2017).

1.3. Resultados e Discussão

Os valores médios dos índices de vegetação, avaliações morfofisiológicas, qualidade de grãos e produtividade em 2018 e 2019 são apresentados nas Tabelas 2 e 3. Na análise de variância multivariada conjunta, foram encontradas diferenças para as fontes de variação cultivares ($p < 0,01$), regimes hídricos ($p < 0,01$), ano de cultivo ($p < 0,01$) e para a interação cultivares x regimes hídricos ($p < 0,01$). Não houve significância ($p = 0,09$) para a interação

cultivares x regimes hídricos x ano de cultivo. A significância da interação demonstra que as cultivares respondem de forma diferente à disponibilidade de água. Considerando o objetivo deste trabalho, esta é uma oportunidade para validar a metodologia de seleção e selecionar genótipos adaptados ao crescimento em estresse hídrico.

Pela representação *biplot* da decomposição em valores singulares (Figura 3), a coordenada principal 1 (variável latente), reteve 56% da variação multivariada de regimes hídricos e cultivares, enquanto, a coordenada 2 reteve 9,9% da variação. O *biplot* é uma representação gráfica útil de análise de dados e permite a avaliação visual da estrutura de grandes matrizes de dados. É capaz de mostrar distâncias entre unidades e indicar o agrupamento de unidades, bem como exibir variâncias e correlações das variáveis (GABRIEL, 1971). De acordo com Rencher (2002), pelo menos 60% da variância total deve ser explicada pelos dois primeiros componentes principais.

Os regimes hídricos tiveram maior influência na resposta multivariada do que as cultivares, com forte contraste entre as cultivares no RH1 (31% da reposição da ETc) em comparação com as cultivares no RH4 (100% da reposição da ETc). Em RH3 e RH2 (64 e 44% da reposição da ETc, respectivamente), os genótipos de soja geralmente apresentaram valores intermediários em todas as variáveis estudadas (Figura 3).

Variáveis cujos vetores estavam no mesmo sentido ou com cosseno do ângulo entre eles próximo de um, apresentaram forte correlação positiva (Figura 3). Por exemplo, as variáveis EUA, iEUA e o teor de proteína são correlacionadas (Figura 4). Da mesma forma, as variáveis do lado esquerdo (valores negativos no *biplot*), ou seja, índices vegetativos (NDVI, GNDVI, GRVI, DVI, NDWI, NDRE, SAVI, PRI, OSAVI, TCARI) e trocas gasosas (A , g_s , E) são correlacionados (Figura 4) e apresentaram contribuições similares para com a variabilidade dos tratamentos (eixo Coord1), com coeficientes próximos de 1.3 (Figura 3).

Em contrapartida, a variável EUA e a assimilação líquida de CO₂ (A) possuem correlação forte negativa (0,75, $p < 0,01$) (Figura 4). Não existe correlação (ou correlação fraca) entre as variáveis altura de plantas e rendimento de grãos, pois forma um ângulo próximo de 90 graus. Por outro lado, as variáveis relativas aos índices vegetativos, trocas gasosas e a EUA mostraram uma forte correlação negativa (-0,75, $p < 0,01$) (Figuras 1 e 2) são importantes no estudo para diferenciar os tratamentos. Não houve correlação (ou houve fraca correlação) entre altura de plantas e produtividade, pois apresentam um ângulo de 90 graus entre elas. O comprimento das setas indica as variáveis mais importantes na diferenciação dos tratamentos. Por outro lado, o diâmetro do coleto, teor de óleo, peso hectolitro, germinação e grãos por vagem apresentaram peso baixo para a discriminação de regimes hídricos e cultivares (Figura 3).

As cultivares no RH4 encontram-se mais no extremo esquerdo do gráfico, e conseqüentemente, apresentam maiores índices vegetativos e atividade fotossintética, o que promoveu maiores rendimentos de grãos. As cultivares no RH1, sob estresse severo, apresentam maiores índices em variáveis como EUA, porcentagem de proteína nos grãos e TO (TCARI/OSAVI) (Figura 3).

Os menores índices destas cultivares foram obtidos nas variáveis representadas por vetores no sentido oposto como NDVI, A, g_s , GNDVI, entre outras. A TO representa um preditor espectral das concentrações de pigmentos na escala do dossel, sendo bastante sensível à variação de clorofila e resistente ao efeito da reflectância de solo e de matérias não fotossintéticas (DAMM et al., 2018).

Os resultados apresentados na Figura 5A mostram que os modelos são adequados para explicar a variação da coordenada principal 1 (variável latente) em todos as cultivares. O incremento no índice do valor é logarítmico e negativo e, diferente entre as cultivares de soja.

Em geral, o aumento na disponibilidade hídrica aumentou os índices de vegetação, a atividade fotossintética e o rendimento de grãos (Figura 5A, Tabelas 2 e 3).

Um exemplo da diferença de resposta entre as cultivares, é a discrepância da cultivar BRS 7180IPRO no RH1 em relação às demais cultivares, sua resposta é mais rápida a presença de água (Figura 5A). Isso é verificado também nos modelos de regressão para Coord1, que representa uma combinação linear de todas as variáveis resposta, com a qual percebe-se que BRS 7180IPRO responde 1,5 vezes mais rápido que a cultivar BRS 7280RR e 1,34 que a BRS 5980IPRO, por exemplo. Sendo assim, mudanças na disponibilidade hídrica implicará em alterações significativas em todas essas variáveis representadas pela variável latente.

De maneira geral, as cultivares apresentaram respostas exponenciais para as variáveis rendimento de grãos (Figura 5B) e atividade fotossintética (Figuras 5C) em função do regime hídrico, ou seja, o aumento da disponibilidade de água aumenta a atividade fotossintética da planta e promove melhor formação e enchimento de grãos (ALI et al., 2017).

Independentemente da disponibilidade hídrica, as cultivares BRS 7280RR e NA 5909RG apresentaram maiores rendimentos de grãos (Tabela 3) e resultados superiores ou semelhantes nas variáveis fotossíntese, EUA e NDVI, dentro de cada regime hídrico (Tabelas 2 e 3). Assim, essas cultivares apresentam alto desempenho produtivo sob maior e menor disponibilidade hídrica, podendo ser recomendadas para o cultivo na região do Cerrado.

Por outro lado, as cultivares BRS 5980IPRO e BRS 7180IPRO apresentam redução de 14% para as variáveis EUA e NDVI, enquanto M 6410IPRO e BRS 7380RR apresentam respostas intermediárias (Tabelas 2 e 3). A capacidade em manter o rendimento e a qualidade de grãos em condições de deficiência hídrica possivelmente está relacionado à forte associação entre a assimilação de fotossintatos e a melhor mobilização de carboidratos por genótipos tolerantes à seca (FAHAD et al., 2017). Além disso, os déficits hídricos provocam alterações

no metabolismo das plantas que afetam a produtividade, dependendo do grau de estresse, dos genótipos e das influências das condições ambientais (IQBAL et al., 2018).

De forma geral, a taxa fotossintética diminuiu gradativamente entre as cultivares com redução da disponibilidade hídrica (Tabela 2, Figura 5C). Comparando-se condições de alta (RH4) e baixa disponibilidade de água (RH1), observou-se uma redução da taxa fotossintética em média de 70% nas cultivares de soja. Resultados semelhantes foram obtidos por Zhang et al. (2016), em que a redução na disponibilidade de água causou diminuição da taxa fotossintética, condutância estomática e transpiração, pois esses processos estão intimamente ligados e, como demonstrado na Figura 3, apresentam uma alta correlação positiva.

A resposta fotossintética das cultivares em relação à disponibilidade de água apresenta similaridade, pois os coeficientes de regressão (b) apresentam valores próximos à média (0,11) (Figura 5C). No RH1, as cultivares apresentaram valores similares de assimilação líquida de CO₂ (Figura 5C). No entanto, com a redução da disponibilidade hídrica, a resposta das cultivares se diferenciam, e BRS 7280 RR destacou-se em todos os regimes hídricos com maior eficiência na assimilação de CO₂.

Basal et al. (2020) relatam que sob déficit hídrico, a turgidez celular e a proporção de estômatos abertos são afetados, o que resulta em diminuições nas taxas de transpiração e assimilação de CO₂. A taxa de transpiração das cultivares foi afetada pela deficiência hídrica, por ser regulada pela abertura e fechamento estomático. Assim, à medida que a disponibilidade de água no solo diminui, os valores de transpiração decrescem, como resultado do fechamento dos estômatos.

A g_s é considerada um indicador bastante sensível ao déficit hídrico nas plantas, o que possibilita o uso dessa variável na avaliação de genótipos adaptados para o cultivo em ambientes com limitada disponibilidade hídrica, sendo considerado um dos maiores fatores de limitação da fotossíntese (FLEXAS et al., 2014).

Quando os estômatos estão abertos, permitem a assimilação de CO₂ e ocorre a perda de H₂O e com seu fechamento, há redução da entrada de CO₂ para os sítios de carboxilação da rubisco no interior dos cloroplastos e conservam H₂O, reduzindo o risco de desidratação, contudo, causa perda na taxa fotossintética líquida (JUMRANI e BHATIA, 2019).

A redução no conteúdo relativo de água na folha, condutância estomática, concentração de dióxido de carbono subestomático, taxa transpiratória e na taxa de fotossíntese de soja cultivada sob estresse hídrico são relatados por Mwamlima et al. (2019) e Castro et al. (2019).

A eficiência agrônômica no uso da água refere-se ao rendimento de grãos obtido por unidade de água aplicada. Esse é um parâmetro fisiológico fundamental que indica a capacidade das culturas de conservar água em uma região com escassez de água, porque combina tolerância à seca e ao alto potencial de rendimento, sendo uma utilização prática quanto ao uso eficiente da água aplicada (ZHANG et al., 2016).

As cultivares geralmente apresentaram o mesmo modelo de resposta, e a maior EUA ocorreu entre os RH1 e RH2 independentemente da cultivar (Figura 5D, Tabela 3). Nos RH3 e RH4 houve menor EUA, possivelmente devido à perda por percolação de parte da água fornecida (MEENA et al., 2019). Segundo Bertolino et al. (2019), plantas em condição de restrição hídrica apresentam aumento na EUA uma vez que a redução apenas parcial da abertura estomática limita mais fortemente a transpiração do que a entrada de CO₂, aumentando a EUA.

O genótipo BRS5980IPRO apresentou o menor EUA, embora não o menor iEUA, o que é mais uma avaliação fisiológica do que agrônômica. Esta avaliação fisiológica foi maior no genótipo BRS7280RR do que nos demais, mostrando boa capacidade de manter eficiência a nível foliar. Considerando os dados obtidos na variável iEUA (A/g_s , eficiência intrínseca do uso da água), a maior eficiência foi obtida ao nível foliar nos tratamentos com menor água (Tabela 1). Gorthi et al. (2019) relataram que variedades de soja de alto rendimento sob seca toleram a escassez de água, reforçando suas defesas fotoprotetoras e promovendo o crescimento

e a produtividade, e esses processos estão ligados a uma maior eficiência no uso da água foliar. Ademais, Lopez et al. (2019) consideram a taxa fotossintética e a iEUA características a serem usadas no melhoramento genético de soja.

As cultivares BRS 5980IPRO e BRS 7180IPRO, em cultivo de inverno, possuem produtividade máxima em torno de 3300/3400 kg ha⁻¹ e atingem essa produtividade em resposta à disponibilidade hídrica rapidamente, com cerca de 45% da evapotranspiração da cultura (Figura 5B). Sua velocidade de resposta é 2,6; 3; 3,9; 4,1 e 3,6 vezes mais rápido que as cultivares BRS 5980IPRO, BRS 7280RR, BRS 7380RR, M 6410IPRO e NA 5909RG, respectivamente. Por outro lado, o genótipo BRS 7280RR apresenta maior produtividade e continua respondendo ao longo do fornecimento de água, com uma boa eficiência no seu uso.

As cultivares de soja responderam de forma logarítmica para a variável NDVI, mostrando que quanto maior a disponibilidade de água, mais as plantas vegetam e aumentam a área foliar (Figura 5E). No entanto, a velocidade que essa resposta acontece é diferente entre as cultivares.

Como observado nas variáveis de trocas gasosas e rendimento de grãos, o genótipo BRS 7180IPRO responde rapidamente à variação na disponibilidade de água, demonstrando similaridade nos resultados, mostrando que há correlação entre essas variáveis. Houve incremento médio do NDVI de 90% nas cultivares, quando comparado o maior e o menor regime hídrico, (Tabela 2, Figura 5E) evidenciando que a disponibilidade de água interfere nos índices de vegetação da cultura.

De acordo com Fried et al. (2019), plantas sob estresse apresentam mudanças nas respostas espectrais, pois essa condição promove a redução na área foliar, aumento no grau de senescência, altera o ângulo de inserção, distribuição e espaçamento das folhas. Além disso, ocorre redução na concentração de clorofila, na atividade fotossintética e o desarranjo nas estruturas internas da folha, promovendo alterações nos índices de vegetação.

Sobejano-Paz et al. (2020) relatam que os índices de vegetação NDVI, TCARI, OSAVI, PRI são eficientes para detecção de plantas de milho e soja em condições de estresse hídrico. Zhou et al. (2021) encontraram que os índices NDVI e GNDVI correlacionaram-se significativamente com o rendimento de grãos em soja sob déficit hídrico.

Nossos resultados mostraram que os dados fisiológicos (A e g_s) tiveram alta correlação com a produtividade, mas não podem ser feitos em larga escala, enquanto os índices vegetativos NDVI e GNDVI de alto rendimento foram os que apresentaram maior correlação com rendimento e pode ser uma ferramenta útil em programas de melhoramento. Os índices de vegetação tiveram, em geral, correlação entre si, podendo um deles ser escolhido para o processo de seleção. Entre os dados morfológicos o número de vagens teve uma maior correlação com a produtividade, mas também é uma avaliação demorada (Figura 2).

Esses resultados também são relatados por Braga et al. (2020), que as medidas de trocas gasosas e os índices de vegetação são capazes de diferenciar as respostas de genótipos de soja em relação à disponibilidade de água, sendo que, em alguns casos, os índices e bandas são mais sensíveis do que as trocas gasosas para detectar o efeito do genótipo, principalmente índices que utilizam bandas na faixa do infravermelho.

Silva et al. (2020a) relatam que os índices SAVI e NDVI destacaram-se pela previsão de rendimento em soja, onde as regiões com os maiores valores desses índices podem obter o maior rendimento de grãos observado no campo, proporcionando uma vantagem na gestão no nível da propriedade utilizando sensor multiespectral acoplado em veículo aéreo não tripulado.

Em relação à qualidade dos grãos de soja, houve uma correlação negativa entre o conteúdo de óleo e de proteínas, sendo que, em ambientes com menores disponibilidade hídrica ocorreu maior acúmulo de proteínas (Figura 3, Figura 4). O maior acúmulo de proteínas também foi observado por (SILVA et al., 2020b) no feijoeiro, com aumento de 20,57% no regime hídrico mais baixo (187 mm) em relação ao regime hídrico mais alto (535 mm).

A ocorrência de uma correlação negativa entre os níveis de óleo e proteínas nos grãos, pode ser explicada pela competição das respectivas vias de síntese pelos esqueletos carbônicos, mudanças no acúmulo e partição de nutrientes nas sementes de soja sob condição de estresse hídrico (WIJewardana et al., 2019), somado à aceleração da maturação e senescência precoce, o que promove a antecipação do ciclo e redução do período fotossintético e de acúmulo de reservas, fazendo com que os grãos das plantas estressadas não apresentem o padrão normal de desenvolvimento e composição química (CHACON et al., 2017).

Esse resultado torna um desafio para os geneticistas, que buscam aumentar os teores de óleo e proteínas, que são desejáveis para o processamento de produtos de soja de qualidade. Wijewardana et al. (2019) encontraram redução nos teores de proteína em grãos de soja, ácidos palmítico e linoléico, sacarose, rafinose, estaquiose, N, P, K e Ca; no entanto, houve aumento dos ácidos óleo, esteárico, oleico e linolênico, Fe, Mg, Zn, Cu e B sob condições de baixa umidade do solo.

1.4. Conclusões

O estresse hídrico afetou negativamente as trocas gasosas, os índices de vegetação, o rendimento e as proteínas dos grãos de forma diferente nas cultivares de soja estudadas.

Os índices de vegetação estão relacionados com as respostas morfofisiológicas e agronômicas de soja e são variáveis de alto rendimento mais responsivas ao estresse hídrico, podendo predizer a capacidade produtiva na soja, conforme demonstrado no *biplot* e na análise de correlação.

As cultivares de soja BRS 7280RR e NA 5909RG nas condições de inverno, apresentam melhor desempenho produtivo tanto na maior quanto na menor disponibilidade hídrica.

Considerando todos os parâmetros, a cultivar de soja BRS 7280 mostrou melhor tolerância à seca e EUA, nesta época de cultivo.

No geral, o estudo destaca o impacto potencial da disponibilidade reduzida de água em características que são importantes para produtores e consumidores, mas também indica cultivares e que são minimamente afetados por essa condição.

1.5. Referências

ALEXANDER, L.V. Global observed long-term changes in temperature and precipitation extremes: a review of progress and limitations in IPCC assessments and beyond. **Weather and Climate Extremes**, v. 11, p. 4–16, 2016. <https://doi.org/10.1016/j.wace.2015.10.007>.

ALI, F.; AHSAN, M.; ALI, Q.; KANWAL, N. Phenotypic stability of *Zea mays* grain yield and its attributing traits under drought stress. **Frontiers in Plant Science**, v. 8, n. 1, p. 1-11, 2017. DOI: <https://doi.org/10.3389/fpls.2017.01397>

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. FAO Irrigation and Drainage Paper, 56, Rome, p. 300, 1998.

BALLESTER, C.; ZARCO-TEJADA, P. J.; NICOLÁS, E.; ALARCÓN, J. J.; FERERES, E.; INTRIGLIOLO, D. S.; GONZALEZ-DUGO, V. Evaluating the performance of xanthophyll, chlorophyll and structure-sensitive spectral indices to detect water stress in five fruit tree species. **Precision Agriculture**, v. 19, p. 178–193, 2018. DOI: <https://doi.org/10.1007/s11119-017-9512-y>

BASAL, O.; SZABÓ, A.; VERES, S. Physiology of soybean as affected by PEG-induced drought stress. **Current Plant Biology**, v. 22, n. 100135, 2020. DOI: <https://doi.org/10.1016/j.cpb.2020.100135>

BERTOLINO, L. T.; CAINE, R. S.; GRAY, J. E. Impact of stomatal density and morphology on water-use efficiency in a changing world. **Frontiers in Plant Science**, v. 10, p. 225, 2019. DOI: <https://doi.org/10.3389/fpls.2019.00225>

BOX, G. E. P. A general distribution theory for a class of likelihood criteria. **Biometrika**, 36, 317-346, 1949. DOI: <https://doi.org/10.2307/2332671>.

BRAGA, P.; CRUSIOL, L. G. T.; NANNI, M. R.; CARANHATO, A. L. H.; FUHRMANN, M. B.; NEPOMUCENO, A. L.; NEUMAIER, N.; FARIAS, J. R. B.; KOLTUN, A.; GONÇALVES, L. S. A.; MERTZ-HENNING, L. M. Vegetation indices and NIR-SWIR spectral bands as a phenotyping tool for water status determination in soybean. **Precision Agriculture**, v. a, p. 1, 2020. DOI: <https://doi.org/10.1007/s11119-020-09740-4>

BUEZO, J.; SANZ-SAEZ, A.; MORANA, J. F.; SOBAA, D.; ARANJUELO, I.; ESTEBAN, R. Drought tolerance response of high-yielding soybean varieties to mild drought: physiological and photochemical adjustments. **Physiologia Plantarum**, v. 166, n. 1, p. 88–104, 2019. DOI: <https://doi.org/10.1111/ppl.12864>

CASTRO, J. N.; MULLER, C.; ALMEIDA, G. M.; COSTA, A. C. Physiological tolerance to drought under high temperature in soybean cultivars. **Australian Journal of Crop Science**, v. 13, n. 6, p. 976-987, 2019. DOI: [10.21475/ajcs.19.13.06.p1767](https://doi.org/10.21475/ajcs.19.13.06.p1767)

CATTELAN, A. J.; DALL'AGNOL, A. The rapid soybean growth in Brazil. **Oilseeds & fats Crops and Lipids**, v.25, p.1-12, 2018. DOI: doi.org/10.1051/ocl/2017058.

CHACON, D. P.; BARAJAS, E. M.; ESTEVA, A. G.; DELGADO, R. L.; SHIBATA, J. K.; VALDIVIA, C. B. P. Biomass remobilization in two common bean (*Phaseolus vulgaris*) cultivars under water restriction. **South African Journal of Botany**, v. 112, p. 79-88, 2017. DOI: <https://doi.org/10.1016/j.sajb.2017.05.015>.

CRUSIOL, L. G. T.; CARVALHO, J. D. F. C.; SIBALDELLI, R. N. R.; NEIVERTH, W.; RIO, A.; FERREIRA, L. C.; PROCÓPIO, S. O.; MERTZ-HENNING, L. M.; NEPOMUCENO, A. L.; NEUMAIER, N.; FARIAS, J. R. B. NDVI variation according to the time of measurement, sampling size, positioning of sensor and water regime in different soybean cultivars. **Precision Agriculture**, 18, 470-490, 2017. DOI: <https://doi.org/10.1007/s11119-016-9465-6>.

DAMM, A.; PAUL-LIMOGES, E.; HAGHIGHI, E.; SIMMER, C.; MORSDORF, F.; SCHNEIDER, F. D.; VAN DER TOL, C.; MIGLIAVACCA, M.; RASCHER, U. Remote sensing of plant-water relations: An overview and future perspectives. **Journal of Plant Physiology**, v. 227, p. 3-19, 2018. DOI: <https://doi.org/10.1016/j.jplph.2018.04.012>

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, p. 229-239, 2000. DOI: [doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)

EMBRAPA. Programa De Monitoramento Da Irrigação. EMBRAPA, Brasília, 2011.

FAHAD, S.; BAJWA, A. A.; NAZIR, U.; ANJUM, S. A.; FAROOQ, A.; ZOHAIIB, A.; SADIA, S.; NASIM, W.; ADKINS, S.; SAUD, S.; IHSAN, M. Z.; ALHARBY, H.; WU, C.; WANG, D.; HUANG, J. Crop Production under Drought and Heat Stress: Plant Responses and Management Options. **Frontiers in Plant Science**, v. 8, n. 29, p. 1-17, 2017. DOI: <https://doi.org/10.3389/fpls.2017.01147>

FAO. How to feed the world – 2050: high-level expert forum. Food and Agriculture Organization of the United Nations. Rome, 2009. Available online: https://reliefweb.int/sites/reliefweb.int/files/resources/DD85967BC807184AC125764900433678-Full_Report.pdf.

FLEXAS, J.; DIAZ-ESPEJO, A.; GAGO, J.; GALLÉ, A.; GALMÉS, J.; GULÍAS, J.; MEDRANO, H. Photosynthetic limitations in Mediterranean plants: a review. **Environmental and Experimental Botany**, v. 103, n. 1, p. 12-23, 2014. DOI: <https://doi.org/10.1016/j.envexpbot.2013.09.002>

FRIED, H. G.; NARAYANAN, S.; FALLEN, B. Evaluation of soybean [*Glycine max* (L.) Merr.] genotypes for yield, water use efficiency, and root traits. **PLoS One**, v. 14, n. 2, p. 1-18, e0212700, 2019. DOI: <https://doi.org/10.1371/journal.pone.0212700>

GABRIEL, K. R. The biplot graphical display of matrices with application to principal component analysis. **Biometrika**, 58, 453-467, 1971. DOI: <https://doi.org/10.2307/2334381>.

GAMON, J. A.; PENUELAS, J.; FIELD, C.B.A. Narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, n. 1, p. 35-44, 1992. DOI: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)

GENTY, B.; BRIANTAIS, J. M.; BAKER, N. R. The relationship between the quantum yield of photosynthetic electron transport and quenching of chlorophyll fluorescence. **Biochimica et Biophysica Acta**, 990, 87-92, 1989. DOI: [https://doi.org/10.1016/S0304-4165\(89\)80016-9](https://doi.org/10.1016/S0304-4165(89)80016-9).

GITELSON, A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology**, v. 22, n.3, p. 247-252, 1994. DOI: [https://doi.org/10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)

GORTHI, A.; VOLENEC, J. J.; WELP, L. R. Stomatal response in soybean during drought improves leaf-scale and field-scale water use efficiencies. **Agricultural and Forest Meteorology**, v. 276, 107629, 2019. DOI: <https://doi.org/10.1016/j.agrformet.2019.107629>

GURUMURTHY, S.; SARKAR, B.; VANAJA, M.; LAKSHMI, J.; YADAV, S. K.; MAHESWARI, M. Morpho-physiological and biochemical changes in black gram (*Vigna mungo* L. Hepper) genotypes under drought stress at flowering stage. **Acta Physiologiae Plantarum**, 41, 1-14, 2019. DOI: <https://doi.org/10.1007/s11738-019-2833-x>.

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrowband vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, p. 416-426, 2002. DOI: [doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)

HANKS, R. J.; KELLER, J.; RASMUSSE, V. P.; WILSON, G. D. Line source sprinkler for continuous variable irrigation crop production studies. **Soil Science Society of America Journal**, v. 40, n. 3 p. 426-429, 1976. DOI: <https://doi.org/10.2136/sssaj1976.03615995004000030033x>

HATFIELD, J. L.; SAUER, T. J.; PRUEGER, J. H. Managing soils to achieve greater water use efficiency: a review. **Agronomy Journal**, v.93, p.271-280, 2001. DOI: <https://doi.org/10.2134/agronj2001.932271x>

HEIL, C. Rapid, Multi-Component Analysis of Soybeans by FT-NIR Spectroscopy. Madison: Thermo Fisher Scientific, 2010. 3 p. (Application note: 51954). Available at: [https://tools.thermofisher.com/content/sfs/brochures/AN-51954-Rapid-Multi-omponent - Analysis-Soybeans-AN51954-EN.pdf](https://tools.thermofisher.com/content/sfs/brochures/AN-51954-Rapid-Multi-omponent-Analysis-Soybeans-AN51954-EN.pdf). Accessed on: 27 jan. 2020.

- HIJMANS, R. J. **Raster**: Geographic data analysis and modeling. R package version 2.2-31. [on-line3], 2014. <http://CRAN.Rproject.org/package=raster>
- IQBAL, N.; HUSSAIN, S.; ZHANG, X. W.; YANG, C. Q.; RAZA, M. A.; DENG, J. C.; AHMAD, S.; ASHGAR, M. A.; ZHANG, J.; YANG, W.; LIU, J. Imbalance water deficit improves the seed yield and quality of soybean. **Agronomy**, v 8, n. 9, 2018. DOI: <https://doi.org/10.3390/agronomy8090168>
- JAYME-OLIVEIRA, A.; RIBEIRO JUNIOR, W. Q.; RAMOS, M. L. G.; ZIVIANI, A. C.; JAKELAITIS, A. Amaranth, quinoa, and millet growth and development under different water regimes in the Brazilian Cerrado. **Pesquisa Agropecuária Brasileira**, v. 52, n. 8, 561–571, 2017. <https://doi.org/10.1590/s0100-204x2017000800001>
- JUMRANI, K.; BHATIA, V. S. Identification of drought tolerant genotypes using physiological traits in soybean. **Physiology and Molecular Biology of Plants**, v. 25, p. 697–711, 2019. DOI: <https://doi.org/10.1007/s12298-019-00665-5>
- LOPES, A. S.; GUIMARÃES, G. L. R. A career perspective on soil management in the Cerrado region of Brazil. **Advances in Agronomy**, v. 137, p. 1–72, 2016. DOI: <https://doi.org/10.1016/bs.agron.2015.12.004>
- LOPEZ, M. A.; XAVIER, A.; RAINEY, K. M. Phenotypic Variation and Genetic Architecture for Photosynthesis and Water Use Efficiency in Soybean (*Glycine max* L. Merr). **Frontiers in Plant Science**, v. 10, 680, 2019. DOI: <https://doi.org/10.3389/fpls.2019.00680>
- MEENA, R. P.; VENKATESH, K.; SENDHIL, R.; KHOBA, R.; SHARMA, R. K.; TRIPATHI, S. C.; SINGH, G. P. Identification of water use efficient wheat genotypes with high yield for regions of depleting water resources in India. **Agricultural Water Management**, v. 223, 105709, 2019. DOI: <https://doi.org/10.1016/j.agwat.2019.105709>.
- MICASENSE. How do professional multispectral cameras differ from single-imager multispectral câmeras - RedEdge-MX 2020. Disponível em: <<http://www.micasense.com/>>. Acesso em: 25.fev.2020.
- MAIMAITIYIMING, M.; GHULAM, A.; BOZZOLO, A.; WILKINS, J. L.; KWASNIEWSKI, M. T. Early detection of plant physiological responses to different levels of water stress using reflectance spectroscopy. **Remote Sensing**, 9, 745, 2017. DOI: <https://doi.org/10.3390/rs9070745>.

MWAMLIMA, L. H.; OUMA, J. P.; CHERUIYOT, E. K. Physiological response of soybean [*Glycine max* (L) Merrill] to soil moisture stress. **African Journal of Agricultural Research**, v. 14, n. 16, p. 729-739, 2019. DOI: 10.5897/AJAR2019.13961

PEREIRA, L. F.; RIBEIRO JUNIOR, W. Q.; RAMOS, M. L. G.; SANTOS, N. Z.; SOARES, G. F.; CASARI, R. A. C. N.; MULLER, O.; TAVARES, C. J.; MARTINS, É. S.; RASCHER, U.; GUIMARÃES, C. A. L.; PEREIRA, A. F.; MERTZ-HENNING, L. M.; SOUSA, C. A. F. Physiological changes in soybean cultivated with soil remineralizer in the Cerrado under variable water regimes. **Pesquisa Agropecuária Brasileira**, v. 56, e01455, 2021. DOI: 10.1590/S1678-3921.pab2021.v56.01455

PERES, D. J.; CANCELLIERE, A. Analysis of Multi-Spectral Images Acquired by UAVs to Monitor Water Stress of Citrus Orchards in Sicily, Italy. In World Environmental and Water Resources Congress 2021 (pp. 270-278). <https://ascelibrary.org/doi/10.1061/9780784483466.025>.

QIU, R. C.; WEI, S.; ZHANG, M.; SUN, H.; LI, H.; LIU, G.; LI, M. Sensors for measuring plant phenotyping: A review. **International Journal of Agricultural and Biological Engineering**, v. 11, n. 2, p. 1–17, 2018. DOI: 10.25165/j.ijabe.20181102.2696

R CORE TEAM (2017). **R**: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>. [accessed on 15 January 2020]

RENCHER, A. C. **Methods of Multivariate Analysis**. 2 ed. New York: John Wiley & Sons, 2002.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95-107, 1996. DOI: [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **Proc 3rd ERTS Symp 1**, p. 48–62, 1973.

SANTESTEBAN, L. G.; DI GENNARO, S. F.; HERRERO-LANGREO, A.; MIRANDA, C.; ROYO, J. B.; MATESE, A. High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. **Agricultural Water Management**, 183, 49-59, 2017. DOI: <https://doi.org/10.1016/j.agwat.2016.08.026>.

SANTOS, H. G.; JACOMINE, P. K. T.; DOS ANJOS, L. H. C.; DE OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; DE ALMEIDA, J. A.; ARAÚJO FILHO, J. C. de; OLIVEIRA, J. B. de; CUNHA, T. J. F. **Sistema brasileiro de classificação de solos**. Brasília, DF: Embrapa, 2018.

SCHEELBEEK, P. F.; BIRD, F. A.; TUOMISTO, H. L.; GREEN, R.; HARRIS, F. B.; JOY, E. J. M.; CHALABI, Z.; ALLEMN, E.; HAINES, A.; DANGOUR, A. D. Effect of environmental changes on vegetable and legume yields and nutritional quality. **Proceedings of the National Academy of Sciences**, v. 115, n. 26, p. 6804–6809, 2018. DOI: 10.1073/pnas.1800442115

SILVA, E. E.; BAILO, F. H. R.; TEODORO, L. P. R.; SILVA JUNIOR, C. A.; BORGES, R. S.; TEODORO, P. E. UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation. **Remote Sensing Applications: Society and Environment**, v. 18, 100318, 2020a. DOI: <https://doi.org/10.1016/j.rsase.2020.100318>

SILVA, A. N.; RAMOS, M. L. G. R.; RIBEIRO JÚNIOR, W. Q. R.; ALENCAR, E. R.; SILVA, P. C.; LIMA, C. A.; VINSON, C. C.; SILVA, M. A. V. Water stress alters physical and chemical quality in grains of common bean, triticale and wheat. **Agricultural Water Management**, 231, 106023, 2020b. DOI: <https://doi.org/10.1016/j.agwat.2020.106023>.

SOARES, G. F.; RIBEIRO JR, W. Q.; PEREIRA, L. F.; LIMA, C. A.; SOARES, D. D. S.; MULLER, O.; RASCHER, U.; RAMOS, M. L. G. Characterization of wheat genotypes for drought tolerance and water use efficiency. **Scientia Agricola**, v. 78, n. 5, e20190304, 2021. DOI: 10.1590/1678-992X-2019-0304

SOBEJANO-PAZ, V.; MIKKELSEN, T. N.; BAUM, A.; MO, X.; LIU, S.; KÖPPL, C. J.; JOHNSON, M. S.; GULYAS, L.; GARCÍA, M. Hyperspectral and Thermal Sensing of Stomatal Conductance, Transpiration, and Photosynthesis for Soybean and Maize under Drought. **Remote Sensing**, v. 12, n. 19, 2020. DOI: <https://doi.org/10.3390/rs12193182>

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER, A. D. Aerial Color Infrared Photography for Determining Early In-season Nitrogen Requirements in Corn. **Agronomy Journal**, v. 98, p. 968-977, 2006. DOI: <https://doi.org/10.2134/agronj2005.0200>

STEVEN, M. D. The sensitivity of the OSAVI vegetation index to Observational Parameters. **Remote Sensing of Environment**, v. 63, p. 49-60, 1998. DOI: [https://doi.org/10.1016/S0034-4257\(97\)00114-4](https://doi.org/10.1016/S0034-4257(97)00114-4)

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

VAN GENUCHTEN, M.T. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, v.44, p.892-898, 1980. DOI: <https://doi.org/10.2136/sssaj1980.03615995004400050002x>

VILLASENOR-ALVA, J. A.; GONZALEZ-ESTRADA, E. A generalization of Shapiro-Wilk's test for multivariate normality. **Communications in Statistics - Theory and Methods**, 38,1870-1883, 2009. DOI: <https://doi.org/10.1080/03610920802474465>.

WIJEWARDANA, C.; REDDY, K. R.; BELLALLOUI, N. Soybean seed physiology, quality, and chemical composition under soil moisture stress. **Food Chemistry**, v. 278, n. 1, p. 92-100, 2019. DOI: <https://doi.org/10.1016/j.foodchem.2018.11.035>

ZARCO-TEJADA, P. J.; GONZÁLEZ-DUGO, V.; BERNI, J. A. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. **Remote Sensing Environment**, 117, 322-337, 2012. DOI: <https://doi.org/10.1016/j.rse.2011.10.007>.

ZARCO-TEJADA, P. J.; GUILLÉN-CLIMENT, M. L.; HERNÁNDEZ-CLEMENTE, R.; CATALINA, A.; GONZÁLEZ, M. R.; MARTÍN, P. Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). **Agricultural and Forest Meteorology**, 171, 281-294, 2013. DOI: <https://doi.org/10.1016/j.agrformet.2012.12.013>.

ZHANG, B.; FENG, G.; READ, J. J.; KONG, X.; OUYANG, Y.; ADELI, A.; JENKINS, J.N. Simulating soybean productivity under rainfed conditions for major soil types using APEX model in East Central Mississippi. **Agricultural Water Management**, v. 177, p. 379-391, 2016. DOI: <https://doi.org/10.1016/j.agwat.2016.08.022>

ZHAO, Y.; POTGIETER, A. B.; ZHANG, M.; WU, B.; HAMMER, G. L. Predicting Wheat Yield at the Field Scale by Combining High-Resolution Sentinel-2 Satellite Imagery and Crop Modelling. **Remote Sensing**, v. 12, n. 6, 1024, 2020. DOI: <https://doi.org/10.3390/rs12061024>

ZHOU, J.; ZHOU, J.; YE, H.; ALI, M. D. L.; CHEN, P. C.; NGUYEN, H. T.; CHEN, P. Yield estimation of soybean breeding lines under drought stress using unmanned aerial vehicle-based

imagery and convolutional neural network. **Biosystems Engineering**, v. 2014, p. 90-103, 2021.
DOI: <https://doi.org/10.1016/j.biosystemseng.2021.01.017>

1.6. Apêndice

Tabela 1. Características espectrais avaliadas e suas respectivas fórmulas de cálculo.

Índice de Vegetação	Fórmula	Fonte
Normalized Difference Vegetation Index	$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$	Rouse et al., 1973
Green Normalized Difference Vegetation Index	$GNDVI = \frac{(NIR - GREEN)}{(NIR + GREEN)}$	Daughtry et al., 2000
Green-Red Vegetation Index	$GRVI = \frac{NIR}{GREEN}$	Sripada et al., 2006
Difference Vegetation Index	$DVI = NIR - RED$	Tucker, 1979
Normalized Difference Water Index	$NDWI = \frac{(GREEN - NIR)}{(GREEN + NIR)}$	Gao (1996)
Normalized Difference Red Edge	$NDRE = \frac{(NIR - RedEdge)}{(NIR + RedEdge)}$	Gitelson e Merzlyak, 1994
Soil Adjusted Vegetation Index	$SAVI = \frac{[(1 + L)(NIR - RED)]}{(NIR + RED + L)}$	Rondeaux et al., 1996
Photochemical Reflectance Index	$PRI = \frac{(BLUE - GREEN)}{(BLUE + GREEN)}$	Gamon et al., 1992
Optimized Soil Adjusted Vegetation Index	$OSAVI = \frac{(NIR - RED)}{(NIR + RED + 0,16)}$	Steven, 1998
Chlorophyll Absorption and Reflectance Index	$TCARI = 3[(RedEdge - Red) - 0.2(RedEdge - Green)(Red Edge / Red)]$	Haboudane et al., 2002
Relação TCARI/OSAVI	$TO = TCARI / OSAVI$	Haboudane et al., 2002

Tabela 2. Médias das variáveis de índices de vegetação, trocas gasosas e rendimento quântico máximo do fotossistema II em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.

Cultivares	RH	Variáveis														
		NDVI	SAVI	DVI	GNDVI	NDRE	TCARI	OSAVI	TO	PRI	A	g _s	E	Fv/Fm	CI	iEUA
BRS 5980IPRO	31	0.34	0.23	0.14	0.55	0.14	0.16	0.28	0.64	0.30	4.5	0.05	2.1	0.79	232	90.7
	44	0.41	0.27	0.17	0.58	0.18	0.17	0.34	0.58	0.32	10.0	0.11	2.6	0.78	216	90.9
	64	0.46	0.31	0.19	0.60	0.20	0.19	0.38	0.51	0.32	17.8	0.36	5.3	0.81	261	49.4
	100	0.51	0.34	0.20	0.61	0.22	0.21	0.42	0.58	0.33	19.7	0.35	5.0	0.81	256	56.3
BRS 7180IPRO	31	0.42	0.30	0.19	0.58	0.19	0.18	0.35	0.66	0.33	3.7	0.06	2.6	0.75	241	61.7
	44	0.49	0.36	0.24	0.61	0.23	0.21	0.43	0.61	0.35	10.9	0.18	3.5	0.78	226	60.6
	64	0.57	0.41	0.27	0.62	0.25	0.26	0.49	0.55	0.35	18.3	0.33	5.3	0.80	249	55.5
BRS 7280RR	100	0.76	0.53	0.34	0.69	0.31	0.33	0.64	0.52	0.34	19.9	0.36	5.1	0.82	254	55.3
	31	0.39	0.26	0.16	0.58	0.16	0.17	0.32	0.63	0.30	10.0	0.07	2.3	0.79	184	142.9
	44	0.44	0.30	0.19	0.60	0.20	0.18	0.37	0.58	0.34	15.3	0.15	3.2	0.80	204	102.0
	64	0.50	0.35	0.22	0.61	0.22	0.22	0.43	0.53	0.33	20.7	0.33	5.2	0.82	248	62.7
BRS 7380RR	100	0.56	0.38	0.23	0.62	0.23	0.25	0.47	0.58	0.32	21.2	0.35	5.2	0.83	251	60.6
	31	0.37	0.26	0.16	0.55	0.17	0.17	0.31	0.68	0.31	5.3	0.10	2.4	0.78	188	53.0
	44	0.44	0.31	0.20	0.58	0.20	0.19	0.38	0.64	0.35	12.7	0.17	3.5	0.80	217	74.7
	64	0.48	0.34	0.22	0.59	0.21	0.22	0.41	0.57	0.34	18.8	0.33	5.1	0.80	257	57.0
M 6410IPRO	100	0.64	0.44	0.28	0.61	0.24	0.32	0.54	0.65	0.34	20.7	0.36	5.1	0.81	250	57.5
	31	0.39	0.26	0.16	0.56	0.17	0.16	0.33	0.61	0.30	6.9	0.07	2.2	0.78	283	98.6
	44	0.45	0.30	0.19	0.60	0.22	0.17	0.37	0.56	0.34	13.9	0.18	2.9	0.79	216	77.2
	64	0.49	0.34	0.21	0.61	0.23	0.19	0.41	0.50	0.34	19.0	0.29	4.6	0.82	256	65.5
NA 5909GR	100	0.55	0.38	0.23	0.63	0.25	0.22	0.46	0.56	0.34	20.9	0.36	5.2	0.82	251	58.1
	31	0.34	0.22	0.13	0.56	0.15	0.15	0.28	0.60	0.29	7.2	0.06	3.6	0.80	233	120.0
	44	0.41	0.27	0.16	0.59	0.19	0.16	0.34	0.56	0.33	14.0	0.15	3.2	0.82	222	93.3
	64	0.48	0.32	0.19	0.61	0.21	0.20	0.39	0.54	0.34	20.4	0.31	4.7	0.83	251	65.8
	100	0.53	0.35	0.21	0.63	0.23	0.21	0.43	0.55	0.34	21.1	0.36	5.2	0.84	255	58.6
Média		0.33	0.20	0.60	0.21	0.20	0.40	0.58	0.33	4.0	15.9	0.22	4.0	0.80	237	72.2
Erro Padrão		0.02	0.01	0.01	0.01	0.01	0.01	0.02	0.01	0.01	0.68	0.03	0.2	0.01	4.94	0.22
CV		2.03	2.13	2.29	0.52	1.84	2.33	2.07	0.84	0.52	1.86	5.67	3.0	2.19	1.02	3.2

^{1/} RH: regimes hídricos (31, 44, 64 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente); NDVI: Difference Vegetation Index; SAVI: Soil Adjusted Vegetation Index; DVI: Difference Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; NDRE: Red Edge Normalized Difference; TCARI: The Transformed Chlorophyll Absorption and Reflectance Index; OSAVI: Optimized Soil Adjusted Vegetation Index; TO: TCARI/OSAVI Ratio; PRI: Photochemical Reflectance Index; A: Taxa fotossintética ($\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$); g_s: Condutância estomática ($\mu\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$); E: Transpiração ($\text{mmol H}_2\text{O m}^{-2} \text{ s}^{-1}$); Fv/Fm: Rendimento Quântico Máximo do Fotossistema II; CI: Concentração interna de carbono; Eficiência de uso de água intrínseca (iEUA). CV: Coeficiente de variação (%).

Tabela 3. Médias das variáveis morfológicas, rendimento e qualidade grãos em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.

Cultivares	RH	Variáveis														
		A1	AP	DC	NN	NG	GV	UG	PH	MMG	RG	G	EUA	O	P	D
BRS 5980IPRO	31	1.03	25.8	4.7	10.1	18.9	2.06	10.0	63.10	142.8	2338	73.3	11.20	19.1	39.5	23.0
	44	0.96	28.4	4.9	11.6	26.3	2.01	11.1	65.78	141.9	2782	92.6	8.82	19.1	39.6	2.2
	64	0.83	29.3	5.0	11.5	32.4	2.10	11.8	63.15	141.8	3271	92.3	7.20	19.0	39.0	1.0
	100	0.84	30.1	5.2	12.1	36.1	2.08	11.8	64.33	151.4	3351	93.3	4.85	19.6	38.8	0.3
BRS 7180IPRO	31	1.16	35.4	2.7	9.9	22.2	1.98	11.6	61.00	134.0	2419	88.6	9.83	21.4	38.7	5.5
	44	0.98	38.8	5.9	12.2	29.8	2.10	10.7	63.24	152.2	3026	82.0	7.05	19.7	38.5	2.3
	64	1.01	38.9	6.4	11.6	34.3	2.26	11.5	64.70	162.3	3305	69.0	5.45	20.4	37.3	4.7
	100	0.90	42.2	6.3	11.2	39.5	2.09	13.5	63.07	168.5	3431	54.0	4.08	21.3	37.0	0.2
BRS 7280RR	31	1.13	39.9	6.0	11.3	19.3	2.08	10.4	64.70	178.1	3117	86.0	12.03	20.3	40.4	6.2
	44	1.07	36.1	6.0	10.9	28.7	2.17	11.0	63.10	180.2	3628	92.0	8.82	20.7	39.1	2.2
	64	1.13	43.5	5.6	14.5	26.5	2.28	11.1	63.80	203.1	4312	87.3	7.28	19.6	39.8	0.0
	100	1.04	41.5	5.5	11.8	29.7	2.13	11.1	63.72	212.8	4342	87.0	4.86	21.0	38.9	0.7
BRS 7380RR	31	1.06	32.5	5.1	11.6	21.2	2.18	11.5	61.10	133.2	2527	93.6	10.48	19.9	39.7	0.7
	44	0.93	35.5	5.5	12.8	30.6	2.18	11.7	61.07	141.3	3052	91.3	7.90	21.3	38.0	0.2
	64	0.96	37.4	5.6	13.1	36.2	2.20	11.9	62.32	158.0	3474	83.3	5.96	22.1	38.0	0.0
	100	0.95	37.4	5.8	13.9	47.6	2.16	11.9	62.00	173.7	3751	87.3	4.36	22.1	37.6	0.0
M 6410IPRO	31	0.99	32.0	4.9	11.1	17.6	2.09	10.8	62.02	139.1	2604	83.3	10.91	20.6	40.3	14.5
	44	0.94	32.1	4.9	11.1	23.0	2.25	11.2	62.32	148.1	3286	95.6	8.48	20.8	38.9	1.2
	64	0.95	34.3	5.1	12.4	30.8	2.22	11.8	61.60	165.4	3544	90.0	6.18	22.9	36.7	0.0
	100	0.88	35.2	5.0	12.0	33.2	2.08	11.8	63.98	183.3	4013	86.0	4.40	22.6	36.3	0.0
NA 5909GR	31	0.91	25.5	6.7	10.6	19.9	2.05	10.1	62.83	169.7	2910	76.0	11.66	21.9	37.5	19.8
	44	0.85	28.2	5.7	11.0	27.4	1.86	11.3	63.93	167.6	3419	94.6	8.52	21.1	37.9	1.5
	64	0.87	30.0	5.6	12.1	29.9	1.87	11.5	63.73	192.5	4055	90.3	6.82	21.4	37.5	0.2
	100	0.81	31.6	6.1	12.6	41.1	1.82	11.4	65.95	205.4	4261	88.6	4.82	21.8	37.5	1.8
Média		0.96	34.2	6.7	11.80	29.3	2.10	11.3	63.19	164.4	3342	85.7	7.40	20.8	38.4	38.4
Erro Padrão		0.02	1.04	0.93	0.22	1.56	0.02	0.15	0.28	4.75	119.46	1.94	1.02	0.23	0.23	0.23
CV		1.01	1.49	6.76	0.92	2.60	0.58	0.63	0.22	1.41	1.75	1.11	3.48	0.54	0.30	0.30

RH: Regimes hídricos (31, 44, 64 e 100% da reposição ETc - RH1, RH2, RH3 e RH4 respectivamente); A1: altura inserção primeira vagem (cm); AP: altura de planta (cm); DC: diâmetro do coleto (mm); NN: número de nós; NV: número de vagens; GV: grãos por vagem; UG: umidade do grão (%); PH: peso hectolitro; MMG: massa de mil grãos (g); RG: rendimento de grãos (kg ha⁻¹); G: germinação (%); EUA: eficiência no uso da água; O: óleo (%); P: proteína (%); D: sementes duras (%); CV: coeficiente de variação (%).




Figura 1. Precipitação e temperatura média obtidos em uma estação meteorológica automatizada localizada ao lado do experimento, nos anos de 2018 e 2019 e uma série histórica (1974 – 2019).

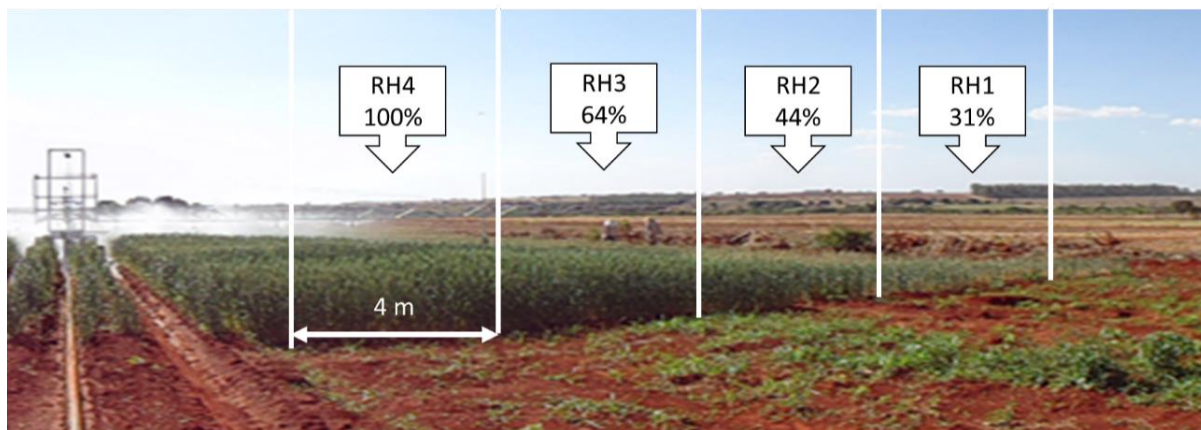


Figura 2. Resumo gráfico das subunidades experimentais (RH1, RH2, RH3 e RH4 - 31, 44, 64 e 100% de reposição da ETC, respectivamente) e da barra de irrigação na cultura da Soja.




Figura 3. *Biplot* para médias de regimes hídricos (31, 44, 64 e 100% ETC - RH1, RH2, RH3 e RH4, respectivamente) e cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR) a partir de variáveis: altura de Plantas (AP); Altura Inserção primeira Vagem (A1); Diâmetro do Colmo (DC); Número de vagens (NV); grão por vagem (GV); Umidade dos Grãos (UG); Massa de Mil Grãos (MMG); Rendimento de Grãos (RG); Eficiência no Uso de Água (EUA); Porcentagem de óleo (O); Porcentagem de Proteína (P); Peso Hectolitro (PH); Porcentagem de Germinação (G). Índice de Vegetação por Diferença Normalizada Verde (GNDVI); Índice Fotoquímico de Reflectância (PRI); Green-Red Vegetation Index (GRVI); Diferença Normalizada do Red Edge (NDRE); Índice de Vegetação por Diferença Normalizada (NDVI); Normalized Difference Water Index (NDWI); Difference Vegetation Index (DVI); Índice de Vegetação Ajustado ao Solo (SAVI); Optimized Soil Adjusted Vegetation Index (OSAVI); The transformed Chlorophyll Absorption and Reflectance Index (TCARI); Relação TCARI/OSAVI (To); Assimilação líquida de CO₂ (A); Condutância Estomática (Gs); Transpiração (E); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Eficiência de uso de água intrínseca (iEUA).




Figura 4. Correlograma de Pearson entre variáveis que representam as variáveis: altura de Plantas (Ap); Altura Inserção primeira Vagem (A1); Diâmetro do Colmo (DC); Número de vagens (NV); grão por vagem (GV); Umidade dos Grãos (UG); Massa de Mil Grãos (MMG); Rendimento de Grãos (RG); Eficiência no Uso de Água (EUA); Porcentagem de óleo (O); Porcentagem de Proteína (P); Peso Hectolitro (PH); Porcentagem de Germinação (G); Índice de Vegetação por Diferença Normalizada Verde (GNDVI); Índice Fotoquímico de Reflectância (PRI); Green-Red Vegetation Index (GRVI); Diferença Normalizada do Red Edge (NDRE); Índice de Vegetação por Diferença Normalizada (NDVI); Normalized Difference Water Index (NDWI); Difference Vegetation Index (DVI); Índice de Vegetação Ajustado ao Solo (SAVI); Optimized Soil Adjusted Vegetation Index (OSAVI); The transformed Chlorophyll Absorption and Reflectance Index (TCARI); Relação TCARI/OSAVI (To); Assimilação líquida de CO₂ (A); Condutância Estomática (Gs); Transpiração (E); Rendimento Quântico Máximo do Fossistema II (Fv/Fm); Eficiência de uso de água intrínseca (iEUA) em função dos regimes hídricos (31, 44, 64 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente) e cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR).

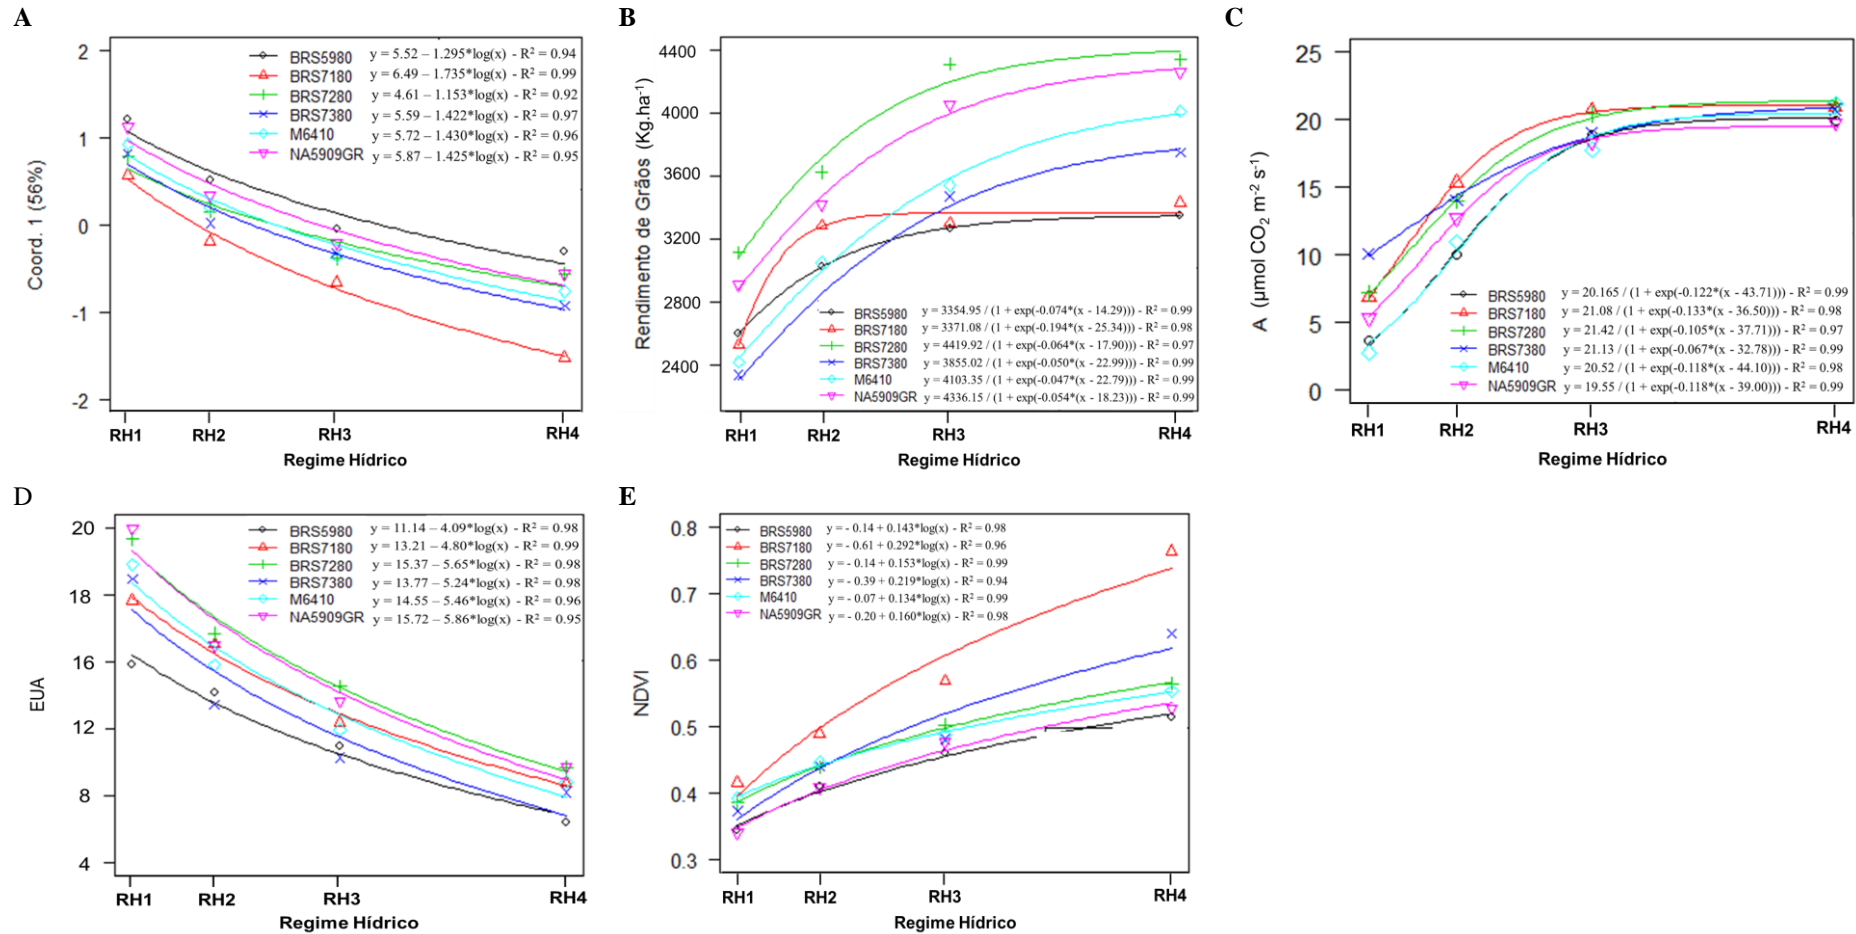


Figura 5. Equações de regressão e os respectivos coeficientes de determinação (R^2) das variáveis: A- Coordenada Principal 1 - variável latente (Coord. 1), B- Rendimento de Grãos, C- Assimilação Líquida de CO_2 (A), D - Eficiência no Uso de Água (EUA) e, E - Índice de Vegetação por Diferença Normalizada (NDVI) em função dos regimes hídricos (RH1, RH2, RH3 e RH4 - 31, 44, 64 e 100% ETC, respectivamente) e cultivares de soja (NA 5909GR; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR).

Capítulo 2 - Correlação canônica entre variáveis espectrais, fisiológicas, de rendimento e qualidade de grãos de cultivares de soja submetidos a estresse hídrico no Cerrado

Resumo - A análise de correlação canônica é uma técnica estatística multivariada que mede a existência e a intensidade da associação entre grupos de variáveis distintas. Nesse sentido, o objetivo deste trabalho foi estimar as correlações canônicas entre índices de vegetação e variáveis fisiológicas, componentes de rendimento e qualidade de grãos de cultivares de soja submetidos ao estresse hídrico em condições de Cerrado. Os experimentos foram realizados em 2018 e 2019, no delineamento de blocos ao acaso, em esquema de parcelas subdivididas. As parcelas foram compostas de seis cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR) e as subparcelas, por quatro regimes hídricos (31, 44, 64 e 100% da reposição da evapotranspiração da cultura - ETc), com três repetições. Os grupos canônicos foram estabelecidos entre as variáveis: índices de vegetação – câmara multiespectral (grupo I), trocas gasosas e fluorescência - Irga (grupo II), componentes de rendimento (grupo III) e variáveis de qualidade de grãos de soja (grupo IV). Os índices de vegetação NDVI, NDRE, TCRI, OSAVI e PRIc estão correlacionados com características de trocas gasosas, fluorescência, produtividade e qualidade dos grãos da soja. O índice de refletância fotoquímica pode ser estimado com precisão a partir de imagens de aeronaves não tripuladas no espectro visível.

Palavras-chave: automação, *Glycine max*, rede de correlação, sensores, tolerância à seca.

2.1. Introdução

A produção de soja (*Glycine max* L. Merrill) desempenha um papel importante na produção agrícola mundial, com impactos na segurança alimentar e nos mercados financeiros (CRUSIOL et al., 2021), sendo o Brasil, o responsável por um terço da produção mundial (USDA, 2021). Apesar dessa grande importância estratégica, a soja pode ter sua produtividade reduzida devido à interação entre genótipo e ambiente (MUTAVA et al., 2015).

Dentre os fatores ambientais, a restrição hídrica é a que mais afeta o desenvolvimento e a produtividade da cultura, principalmente quando ocorrem nos estágios fenológicos reprodutivos, prejudicando cerca de 30% da produção brasileira de soja (SENTELHAS et al., 2015). Assim, estudos sobre as respostas fisiológicas e agronômicas de diferentes genótipos de soja sob diferentes condições edafoclimáticas são de grande importância (CRUSIOL et al., 2021).

No entanto, avaliações *in situ* ou em laboratório são dispendiosas. A utilização de sensores remoto ou proximais, montados em plataformas terrestres (ANDRADE-SANCHEZ et al., 2014) ou em veículos aéreos não tripulados (HAGHIGHATTALAB et al., 2016) vem ganhando espaço por oferecer estimativas precisas do status das plantas, de forma não destrutiva, em qualquer fase de desenvolvimento da cultura (QIU et al., 2018) e alguns ainda fornecem a localização geográfica e permite monitorar grandes áreas de cultivo (HAGHIGHATTALAB et al., 2016).

Esses sistemas podem detectar alterações relacionados à estrutura, pigmentos e eficiência fotossintética da planta e podem fornecer informações valiosas sobre como a fisiologia da planta é afetada pelo estresse (SOBEJANO-PAZ et al., 2020; FENG et al., 2021).

Com a soja há estudos para detecção plantas invasoras (FLETCHER e REDDY, 2016), estresse hídrico (CRUSIOL et al., 2017; MAIMAITIYIMING et al., 2017; PEREIRA et al., 2021), classificação de genótipos (GHULAM et al., 2016; SILVA JUNIOR et al., 2018; CRUSIOL et al., 2021) e predição do rendimento de grãos (YU et al., 2016). Crusiol et al. (2021) indicam que o grande número de cultivares, a diversidade de época de semeadura que gera plantas em diferentes estágios fenológico e a ocorrência de déficits hídricos são fatores que influenciam na avaliação espectral em grande escala na cultura da soja no Brasil. Nesse sentido, comparação entre genótipos deve ser conduzida entre materiais com ciclos semelhantes, evitando-se assim erros experimentais.

Embora o Índice de Vegetação da Diferença Normalizada (NDVI) seja um dos mais utilizados para monitorar o estado da cultura e prever a produtividade, o uso de combinado de outros índices de vegetação tem demonstrado melhor capacidade preditiva (ZHAO et al. 2020; SILVA et al., 2020), existindo necessidade de estudos da interação desses índices de vegetação extraídos com sensores acoplados em veículos aéreos não tripulados com outros tipos de sensores e características da planta para validação e avaliação da acurácia.

Há índices associados a: i) propriedades estruturais da planta, como o índice de vegetação ajustado ao solo otimizado (OSAVI); ii) mudanças de pigmento, como a absorção de clorofila transformada no índice de refletância (TCARI) e a proporção entre TCARI e OSAVI, que reduz o efeito devido às mudanças na área foliar e refletância do solo); e iii) atividade fotoquímica, como o índice de refletância fotoquímica (PRI), que é sensível a mudanças estruturais, níveis de pigmento, exposição do solo, efeitos de iluminação e ângulos do dossel da cultura) (BALLESTER et al., 2018).

O conhecimento das associações que existem entre as características espectrais, fisiológicas, rendimento e qualidade são também de interesse para o melhoramento genético. A associação entre esses grupos de características pode ser avaliada criteriosamente pelo método de análise de correlação canônica, que permite identificar as características em que a seleção deve se basear (OLAWUYI et al., 2014). Portanto, a relação entre variáveis espectrais e agrônômicas de soja deve ser melhor analisada (SILVA JUNIOR et al., 2018; SILVA et al., 2020).

O objetivo deste trabalho foi estimar as correlações canônicas entre índices de vegetação e variáveis fisiológicas, componentes de rendimento e qualidade de grãos de cultivares de soja submetidos ao estresse hídrico no Cerrado.

2.2. Material e Métodos

O experimento foi conduzido a campo experimental, em Planaltina, DF, Brasil (15°35'30'' S e 47°42'30'' W e altitude de 1006 m). O solo é classificado como Oxisol (Soil Survey Staff, 2014), Latossolo Vermelho distroférrico de acordo com Classificação Brasileira de Solo (SANTOS et al., 2018), e apresentou as seguintes características físico-químicas, na profundidade de 0 a 20 cm: pH (CaCl₂) de 5,7; P de 11 mg dm⁻³; K de 186 mg dm⁻³; Ca de 5,77 cmol_c dm⁻³; Mg de 1,83 cmol_c dm⁻³; Al de 0,02 cmol_c dm⁻³ e granulometria de 46, 10 e 44 dag kg⁻¹ de argila, silte e areia, respectivamente.

O clima da região é do tipo Aw (Köppen-Geiger) - Tropical, que possui duas estações do ano bem definidas, com chuvas concentradas no verão (outubro a abril) e um período seco bem definido durante a estação de inverno (maio a setembro), com precipitação média anual que varia de 1200 a 1500 mm. Os dados de precipitação e temperatura da área foram coletados nos anos de 2018 e 2019, em uma estação meteorológica próxima ao experimento (Figura 1). O trabalho foi realizado entre maio e setembro por coincidir com o período de estiagem na região, o que possibilitou o controle do fornecimento de água à cultura.

O delineamento experimental foi em blocos ao acaso em esquema de parcelas subdivididas, com três repetições. Nas parcelas foram alocadas as cultivares de soja (NA 5909RG; M 6410IPRO; BRS 5980IPRO; BRS 7180IPRO; BRS 7280RR; BRS 7380RR) e nas subparcelas quatro regimes hídricos (RH). Em 2018, 160,1 mm, 274,68 mm, 420,55 mm e 634,35 mm foram aplicados durante o ciclo da cultura, correspondendo a RH1, RH2, RH3 e RH4, respectivamente. Em 2019, 164, 79 mm, 237,45 mm, 343,15 mm e 531,43 mm foram aplicados correspondendo a RH1, RH2, RH3 e RH4, respectivamente. Em 2018 e 2019, os regimes hídricos utilizados foram equivalentes a 31%, 44%, 64% e 100% da reposição da evapotranspiração da cultura (ETc).

Cada unidade experimental foi composta por 36 linhas de cultivo de cada cultivar, com 5,0 m de comprimento, em espaçamento de 0,5 m. Cada regime hídrico constituiu uma subunidade experimental de 5,0 m de comprimento, formada por 8 linhas, com espaçamento de 0,50 m, com a área útil constituída pelas duas linhas centrais, descartando-se as bordaduras e 0,5 m de cada extremidade.

O histórico dos últimos 3 anos de cultivo da área experimental é de soja sob diferentes regimes hídricos no inverno e pousio no verão. A área foi dessecada com glifosato na dose de 1440 g.e.a ha⁻¹ aos 20 dias antes da semeadura. As sementes de soja foram previamente inoculadas com *Bradyrhizobium japonicum* (estirpe SEMIA 5080) na dose de 100 mL para 50 kg de sementes. A semeadura foi realizada mecanicamente no dia 02 de junho de 2018 e em 23 de maio de 2019, sob sistema plantio direto, utilizando-se 16 sementes por metro. Na adubação de base aplicou-se 300 kg ha⁻¹ de adubo formulado 04-30-16 (N, P₂O₅, K₂O).

Como tratamentos fitossanitários, visando o controle de vaquinha (*Diabrotica speciosa*), foram realizadas aplicações do inseticida tiametoxam + lambda-cialotrina nas doses de 14,1 g + 10,6 g ha⁻¹ aos 10 e aos 20 dias após a emergência da soja (DAE), no ano de 2018, e aos 12 e 24 DAE, no ano de 2019. A aplicação do herbicida glifosato na dose de 720 g.e.a ha⁻¹ foi realizada aos 18 DAE para controle das plantas daninhas, em ambos os anos.

Aplicou-se a mesma lâmina de água nos primeiros 35 dias após a emergência (DAE), com a reposição média de 140 mm de água, visando obter um estande de plantas homogêneo. Após esse período, foi adotada a metodologia de “line source” (HANKS et al., 1976), modificada pela introdução de uma barra de irrigação (JAYME-OLIVEIRA et al., 2017). Utilizaram-se aspersores com vazão decrescente do meio para a borda da barra, a fim de produzir um gradiente de déficit hídrico. Os regimes hídricos foram obtidos através da barra de irrigação (IrrigaBrasil modelo 36/42), de 20 m de largura em cada lado, conectada a um TurboMaq 75/GB autopropulsor, com velocidade ajustável de acordo com a lâmina de água a ser aplicada.

As irrigações de nível mais alto foram realizadas conforme descrito no programa de monitoramento de irrigação no Cerrado (EMBRAPA, 2011), isto é, através da reposição da evapotranspiração, utilizando-se indicadores agrometeorológicos da região, tipo de solo e data de emergência total das plantas. O programa estima a evapotranspiração de referência com base na equação proposta por Penman-Monteith (ALLEN et al., 1998). A frequência de irrigação foi realizada aproximadamente a cada 5 dias, de acordo com as condições climáticas e a fase fenológica da cultura. Para quantificar a quantidade de água aplicada, em cada irrigação, foram montadas duas fileiras de coletores paralelos à linha de irrigação para medir o volume de água aplicada.

Para a caracterização das variáveis fisiológicas, foram avaliados aos 70 DAE, na fase fenológica R5.1, a assimilação líquida de CO₂ (A), condutância estomática (g_s), a taxa de transpiração (E), concentração interna de CO₂ (C_i) e o rendimento quântico máximo do Fotossistema II (F_v/F_m). Essa avaliação foi realizada das 8:30 às 12:30, sob uma irradiância de 1200 μmol de fótons $\text{m}^{-2} \text{s}^{-1}$ e concentração externa de CO₂ (C_a) de 400 $\mu\text{mol mol}^{-1}$ de ar, com um equipamento de sistema de troca de gás de fluxo aberto portátil (LI-6400xt LI-COR Inc., Lincoln, NE). Em cada parcela, foram feitas três avaliações para quantificar as trocas gasosas. As avaliações foram realizadas na folha central do trifólio superior totalmente expandido, com folhas de soja adaptadas à luz e fisiologicamente maduras.

A avaliação com a câmara multiespectral também foi realizada no estágio R5.1. A câmara multiespectral Micasense RedEdge foi acoplada em um veículo aéreo não tripulado (VANT) de asas rotativas. Esta câmara captura imagens em cinco bandas espectrais, denominadas blue (465-485 nm), green (550-570 nm), red (663-673nm), red edge (712-722nm), near infra-red (NIR) (820-860 nm), com resolução óptica de 1280 x 960 pixels, campo

da visão da lente de 47.2 deg. horizontal e imagens gravadas em RAW 12 bits (MICASENSE, 2020). O voo foi realizado a 45 m de altura, às 10:00 h.

Os mapas de reflectância foram calculados a partir da geração dos ortomosaicos no software Pix4D Mapper (v5.4.6, Pix4D, Lausanne, Suíça), com base nas imagens do painel (MicaSense, modelo RP04 CRP) de calibração antes e após cada voo, além da captura da radiação no momento de cada imagem.

Posteriormente, as imagens foram processadas no software R usando o pacote raster (HIJMANS, 2014) e extraídos os índices de vegetação: Normalized Difference Vegetation Index - NDVI (MYNENI et al., 1995); Green Normalized Difference Vegetation Index – GNDVI (DAUGHTRY et al., 2000); Green-Red Vegetation Index- GRVI (Sripada et al. 2006); Difference Vegetation Index - DVI (TUCKER, 1979); Normalized Difference Water Index - NDWI (GAO, 1996); Normalized Difference Red Edge – NDRE (GITELSON e MERZLYAK, 1994); Soil Adjusted Vegetation Index – SAVI (RONDEAUX et al., 1996); Photochemical Physiological Reflectance Index – PRIc (GAMON et al., 1992); Optimized Soil Adjusted Vegetation Index – OSAVI (STEVEN, 1998); Ratio Vegetation Index – RVI (JORDAN, 1969), Chlorophyll Absorption and Reflectance Index – TCARI (HABOUDANE et al., 2002); Relação TCARI/OSAVI – TO (HABOUDANE et al., 2002).

Na colheita da soja, avaliou-se o rendimento de grãos (RG) na área útil de cada subunidade experimental, e na área útil foram colhidas, ao acaso, dez plantas representativas, para a avaliação da altura de inserção da primeira vagem (A1), a altura de plantas (AP), o diâmetro do coleto (DC) e o número total de vagens por planta (VP). Destas plantas foram utilizadas 200 vagens, aleatoriamente, e foi determinado o número de grãos por vagem (GV) e a massa de 1000 grãos (MMG). O rendimento de grãos e a massa de 1000 grãos foram expressos, padronizando-se o teor de água dos grãos para 13% em base úmida.

A eficiência no uso de água (EUA) foi calculada através da relação entre rendimento de grãos e demanda hídrica da cultura (HATFIELD et al., 2001). Posteriormente, foram analisados a qualidade dos grãos (teor de proteínas e óleos), o peso do hectolitro (PH) e germinação (G) e sementes duras (D). As porcentagens de proteína e o óleo foram determinadas em grãos inteiros e sem impurezas pela técnica de Espectroscopia de Reflexão no Infravermelho Próximo (NIRS), de acordo com Heil (2010). A germinação e a porcentagem de sementes duas foram determinadas de acordo com Brasil (2009).

Os dados foram submetidos à análise de variância multivariada conjunta (anos) para modelar as variáveis espectrais e agronômicas em função do regime hídrico. Os resíduos foram

então extraídos para obter a matriz de correlação de Pearson livre dos efeitos dos fatores experimentais. Os resíduos foram testados quanto a normalidade multivariada usando o teste generalizado de Shapiro-Wilk (VILLASENOR-ALVA e GONZALEZ-ESTRADA, 2009), e para homogeneidade de matrizes de covariância usou o teste Box-M (Box, 1949).

Para a análise de correlação canônica, os dados foram divididos em quatro grupos: (I) variáveis da câmera multiespectral, (II) variáveis do analisador de gases infravermelho (IRGA), (III) variáveis de componente de produção e (IV) variáveis de qualidade do grão. Foi feita uma padronização prévia (escalamento) para obter média zero e desvio padrão um, de modo a evitar que a escala das variáveis afetasse a interpretação dos coeficientes das variáveis canônicas. Uma vez determinados os pares canônicos, as correlações entre as variáveis canônicas foram submetidas ao teste da razão de verossimilhança. Uma representação gráfica da matriz foi feita usando uma rede de correlação.

As análises foram realizadas em R (www.r-project.org), com uso dos pacotes *candisc* (FRIENDLY e FOX, 2017) e *qgraph* (EPSKAMP et al., 2012).

2.3. Resultados e Discussão

Os valores médios das variáveis componentes de rendimento, produtividade, eficiência no uso de água, qualidade de grãos, espectrais, trocas gasosas e fluorescência analisadas em seis cultivares de soja, nas safras de 2018 e em 2019, são apresentados nas Tabelas 1 e 2.

Através da rede de correlações construída entre as variáveis espectrais (*Índices de vegetação + Irga*) e variáveis agronômicas de soja (*Componentes de rendimento + Qualidade de grãos*) (Figura 2) é evidenciada a proximidade entre os índices de vegetação, apresentando correlações acima de 0.60 (Figura 2). “TO” foi negativamente correlacionado com NDRE e GNDVI, que é um resultado esperado, pois TO representa um preditor espectral das concentrações de pigmentos na escala do dossel, sendo bastante sensível à variação de clorofila e resistente ao efeito da reflectância de solo e de matérias não fotossintéticas (DAMM et al., 2018).

Os índices de vegetação: NDVI, SAVI, NDRE, GNDVI, GRVI, OSAVI, DVI, NDWI e TCARI são fortemente correlacionados positivamente entre si (Figura 2), e esta parece uma associação provável, uma vez que valores maiores normalmente indicam maior biomassa vegetal (ZHAO et al., 2020).

Yang et al. (2020) relatam que características multiespectrais derivadas de NIR, bandas vermelhas e verdes, mostram forte relação com a biomassa da planta, eficiência no uso de água, fotossíntese e rendimento de grãos em trigo.

Outra estrutura de correlação envolve as características de trocas gasosas e fluorescência: A, E, g_s , CI e Fv/Fm (Figura 2). Pode-se observar que houve associações positivas fortes entre taxa fotossintética, transpiração e condutância estomática, o que é esperado e relatado na literatura, sendo que, em condições de maiores valores de condutância estomática geralmente observa-se maiores valores de transpiração e de taxa fotossintética (YAMORI et al., 2020; COTRIM et al., 2021).

Plantas que apresentam valores de condutância estomática mais elevados, geralmente são mais vigorosas e produtivas, devido à alta correlação desta variável com outras características fisiológicas e rendimento em soja (JUMRANI e BHATIA, 2019; COTRIM et al., 2021).

Em relação aos componentes de rendimento, houve forte correlação positiva entre massa de mil grãos, rendimento de grãos e eficiência no uso de água (Figura 2). As demais características desse grupo: A1, AP, NN, NV, GV e DC possuem correlações positivas fracas. Essas observações corroboram com resultados de outros autores que relatam que cultivares de soja com maior número de nós no caule principal, mais vagens, grãos e massa de mil grãos apresentam maiores produtividades (NAGARAJAN et al., 2017; LI et al., 2021).

No que diz respeito a qualidade de grãos (Figura 2), todas as características pertencentes a este grupo de variáveis foram correlacionadas negativamente, principalmente em relação ao teor de óleo e proteína, que foram fortemente correlacionadas.

A ocorrência de uma correlação negativa entre os níveis de óleo e proteínas nos grãos, pode ser explicada pela competição das respectivas vias de síntese pelos esqueletos carbônicos, mudanças no acúmulo e partição de nutrientes nas sementes de soja sob condição de estresse hídrico (WIJEWARDANA et al., 2019), somado à aceleração da maturação e senescência precoce, o que promove a antecipação do ciclo e redução do período fotossintético e de acúmulo de reservas, fazendo com que os grãos das plantas estressadas não apresentem o padrão normal de desenvolvimento e composição química (CHACON et al., 2017).

Índices espectrais e componentes de rendimento correlacionam positivamente com as variáveis MMG, RG (Figura 2). Por outro lado, em relação ao teor de óleo essas correlações são negativas. Maimaitijiang et al. (2020) relatam um grande potencial no uso de índices de vegetação para prever a produtividade da soja nos EUA; no entanto, os autores recomendam

testes para diferentes culturas e um maior número de genótipos em diferentes estágios de desenvolvimento e condições ambientais.

Silva Junior et al. (2018) destacam o NDVI por correlacionar com o rendimento da cultura e isso deve-se principalmente à absorção da radiação eletromagnética pela planta de forma nítida e pico de refletância na região do infravermelho próximo, tendo como função primária a síntese de clorofila, a-caroteno, b-caroteno e presença de água em sua estrutura.

Os índices que utilizam correção de solo no modelo geralmente apresentam maiores correlações com a produtividade, pois o efeito da refletância do solo não interfere na radiação emitida para o sensor. Silva et al. (2020) encontraram que os índices SAVI e NDVI se destacam pela previsão de produtividade, onde as regiões com os maiores valores desses índices podem obter as maiores produtividades observadas em campo, proporcionando uma vantagem na gestão em nível de propriedade. GNDVI, NDRE e EVI têm correlação negativa na produtividade pela análise de trilha realizada por estes pesquisadores.

Os componentes de rendimento são mais correlacionados com a produtividade que as demais variáveis (Figura 2). Em seguida as variáveis de trocas gasosas mensuradas pelo analisador de gás por infravermelho (IRGA) e posteriormente as variáveis relacionadas a refletância.

A Tabela 3 mostra as correlações canônicas e os primeiros pares canônicos estimados de cada uma das três análises realizadas, pois é o primeiro par canônico que melhor explica a correlação entre os grupos. Para os índices espectrais e os componentes de rendimento, o primeiro par canônico representa 41,1% da correlação total entre as variáveis desses dois grupos, cuja correlação é de 0,69 ($p < 0,01$). Essa relação se deve principalmente aos índices que utilizam as bandas red edge ou NIR, especificamente NDVI, TCARI, OSAVI, NDWI, DVI, SAVI e NDRE com A1, com relação positiva com NDVI, TCARI e OSAVI e relação negativa com NDWI, DVI, SAVI e NDRE.

Zhou et al. (2020) coletaram dados de imagem de 116 genótipos de soja usando um sistema de imagem acoplado em VANT e relatam que: NDVI, NDVI baseado em verde e temperatura estão correlacionados ($p < 0,01$) com o rendimento da soja sob estresse hídrico.

O primeiro par canônico da relação entre índices espectrais e qualidade de grãos representa 58,35% do total de correlação entre as variáveis, com correlação de 0,71 (Tabela 3). A correlação entre os grupos se deve principalmente ao NDVI, OSAVI, SAVI, GNDVI, NDRE e TO com D, O e P. NDVI e OSAVI correlacionam-se positivamente com sementes duras e teor de óleo e negativamente com proteínas, enquanto a correlação é negativa para os demais

variáveis. Isso significa que a soja com maior teor de óleo apresentou maiores índices de NDVI e OSAVI. Portanto, a escolha de um índice depende dos objetivos da seleção.

As correlações canônicas entre índices espectrais e as variáveis de trocas gasosas e fluorescência (Tabela 3) obtidos pelo analisador de gás por infravermelho (IRGA), apresentaram correlação de 0,98 ($p < 0,01$). O primeiro par canônico representa 96,79% da importância relativa entre os grupos de variáveis. A correlação foi dominada por PRIC e condutância estomática. Ademais, NDVI e OSAVI possui correlação com Fv/Fm.

Segundo Feng et al. (2021) o índice de refletância fotoquímica é altamente relacionado ($R^2 = 0,75$; $p < 0,001$) ao indicador térmico de estresse hídrico (índice de estresse hídrico da cultura, CWSI), sendo capaz de identificar mudanças fisiológicas na estrutura dos pigmentos e na regulação estomática com precisão, podendo ser extraídos de sensores de imagem multiespectral e hiperespectral para monitoramento de estresse hídrico em plantas.

Estudos de correlações canônicas são importantes no entendimento das relações entre características fisiológicas (índices de vegetação e trocas gasosas) e os caracteres agrônômicos (componentes de rendimento e qualidade de grãos) em soja, podendo simplificar e determinar quais variáveis são mais importantes na análise. Dada a carência de estudos utilizando correlação canônica para testar a dependência linear entre dados espectrais, produtividade e qualidade de grãos de soja, recomenda-se que novos estudos sejam realizados com outros genótipos e em outras localidades.

2.4. Conclusões

Estes resultados apontam para o interesse em selecionar os índices NDVI, NDRE, TCARI, OSAVI, PRIC que são os correlacionados com características de trocas gasosas, fluorescência, rendimento e qualidade de grãos de soja.

NDVI, TCARI, GNDVI, NDRE e NDWI podem ser usados para estimar o crescimento de plantas de soja e eficiência no uso de água.

NDVI, OSAVI, NDRE e PRIC apresentam boa capacidade de estimar as características de trocas gasosas e rendimento quântico máximo do fotossistema II em plantas de soja.

NDVI, OSAVI, SAVI e NDRE podem ser utilizados para estimar os teores de proteínas e de óleo nos grãos.

Os resultados obtidos demonstram o grande potencial da classificação espectral de genótipos de soja independente do estado hídrico a que as plantas foram submetidas.

2.5. Referências

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. FAO Irrigation and Drainage Paper, 56, Rome, p. 300, 1998.

ANDRADE-SANCHEZ, P.; GORE, M. A.; HEUN, J. T.; THORP, K. R.; CARMO-SILVA, A. E.; FRENCH, A. N.; SALVUCCI, M. E.; WHITE, J. W. Development and evaluation of a field-based high-throughput phenotyping platform. **Functional Plant Biology**, v. 41, n. 1, p. 68-79, 2014. DOI: 10.1071/FP13126

BALLESTER, C.; ZARCO-TEJADA, P. J.; NICOLÁS, E.; ALARCÓN, J. J.; FERERES, E.; INTRIGLIOLO, D. S.; GONZALEZ-DUGO, V. Evaluating the performance of xanthophyll, chlorophyll and structure-sensitive spectral indices to detect water stress in five fruit tree species. **Precision Agriculture**, v. 19, p. 178–193, 2018. DOI: 10.1007/s11119-017-9512-y

BOX, G. E. P. A general distribution theory for a class of likelihood criteria. **Biometrika**, 1949, 36, 317-346. DOI: <https://doi.org/10.2307/2332671>.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Regras para análise de sementes / Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Defesa Agropecuária. – Brasília: Mapa/ACS, 2009. 399 p. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/insumos-agropecuarios/arquivos-publicacoes-insumos/2946_regras_analise__sementes.pdf>. Acesso em: 23.fev.2020.

CHACON, D. P.; BARAJAS, E. M.; ESTEVA, A. G.; DELGADO, R. L.; SHIBATA, J. K.; VALDIVIA, C. B. P. Biomass remobilization in two common bean (*Phaseolus vulgaris*) cultivars under water restriction. **South African Journal of Botany**, v. 112, p. 79-88, 2017. DOI: <https://doi.org/10.1016/j.sajb.2017.05.015>.

COTRIM, M. F.; GAVA, R.; CAMPOS, C. N. S.; DAVID, C. H. O.; REIS, I. A.; TEODORO, L. P. R.; TEODORO, P. E. Physiological performance of soybean genotypes grown under irrigated and rainfed conditions. **Journal of Agronomy and Crop Science**, v. 207, p. 34-43, 2021. DOI: 10.1111/jac.12448

CRUSIOL, L. G. T.; CARVALHO, J. D. F. C.; SIBALDELLI, R. N. R.; NEIVERTH, W.; RIO, A.; FERREIRA, L. C.; PROCÓPIO, S. O.; MERTZ-HENNING, L. M.; NEPOMUCENO, A. L.; NEUMAIER, N.; FARIAS, J. R. B. NDVI variation according to the time of measurement, sampling size, positioning of sensor and water regime in different soybean cultivars. **Precision Agriculture**, v. 18, p. 470-490, 2017. DOI: 10.1007/s11119-016-9465-6

CRUSIOL, L. G. T.; NANNI, M. R.; FURLANETTO, R. H.; SIBALDELLI, R. N. R.; CEZAR, E.; SUN, L.; FOLONI, J. S. S.; MERTZ-HENNING, L. M.; NEPOMUCENO, A. L.; NEUMAIER, N.; FARIAS, J. R. B. Classification of Soybean Genotypes Assessed Under Different Water Availability and at Different Phenological Stages Using Leaf-Based Hyperspectral Reflectance. **Remote Sensing**, v. 13, n. 2, 172, 2021. DOI: 10.3390/rs13020172

DAMM, A.; PAUL-LIMOGES, E.; HAGHIGHI, E.; SIMMER, C.; MORSDORF, F.; SCHNEIDER, F. D.; VAN DER TOL, C.; MIGLIAVACCA, M.; RASCHER, U. Remote sensing of plant-water relations: An overview and future perspectives. **Journal of Plant Physiology**, v. 227, p. 3-19, 2018. DOI: 10.1016/j.jplph.2018.04.012

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, p. 229-239, 2000. DOI: doi.org/10.1016/S0034-4257(00)00113-9

EMBRAPA. Programa De Monitoramento Da Irrigação. EMBRAPA, Brasília, 2011.

EPSKAMP, S.; CRAMER, A. O. J.; WALDORP, L. J.; SCHMITTMANN, V. D.; BORSBOOM, D. qgraph: Network Visualizations of Relationships in Psychometric Data. **Journal of Statistical Software**, v. 48, n. 4, p. 1-18, 2012. DOI: 10.18637/jss.v048.i04

FENG, L.; CHEN, S.; ZHANG, C.; ZHANG, Y.; HE, Y. A comprehensive review on recent applications of unmanned aerial vehicle remote sensing with various sensors for high-throughput plant phenotyping. **Computers and Electronics in Agriculture**, v. 182, 106033, 2021. DOI: 10.1016/j.compag.2021.106033.

FLETCHER, R. S.; REDDY, K. N. Random Forest and leaf multispectral reflectance data to differentiate three soybean varieties from two pigweeds. **Computers and Electronics in Agriculture**, v. 128, p. 199-206, 2016. DOI: 10.1016/j.compag.2016.09.004

FRIENDLY, M.; FOX, J. candisc: Visualizing Generalized Canonical Discriminant and Canonical Correlation Analysis. R package version 0.8-0, 2017. <https://CRAN.R-project.org/package=candisc>

GAMON, J. A.; PENUELAS, J.; FIELD, C.B.A. Narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, n. 1, p. 35-44, 1992. DOI: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)

GHULAM, A.; FISHMAN, J.; MAIMAITIYIMING, M. Spectral separability analysis of five soybean cultivars with different ozone tolerance using hyperspectral field spectroscopy. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 6312-6315, 2016. DOI: 10.1109/IGARSS.2016.7730650.

GITELSON, A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology**, v. 22, n.3, p. 247-252, 1994. DOI: [https://doi.org/10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrowband vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, p. 416-426, 2002. DOI: [doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)

HAGHIGHATTALAB, A.; GONZALEZ, L.; MONDAL, S.; SINGH, D.; SCHINSTOCK, D.; RUTKOSKI, J.; ORTIZ-MONASTERIO, I.; SINGH, R.; GOODIN, D.; POLAND, J. Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries. **Plant methods**, v. 12, n. 1, p. 35, 2016. DOI: 10.1186/s13007-016-0134-6

HANKS, R. J.; KELLER, J.; RASMUSSE, V. P.; WILSON, G. D. Line source sprinkler for continuous variable irrigation crop production studies. **Soil Science Society of America Journal**, v. 40, n. 3 p. 426–429, 1976. DOI: 10.2136/sssaj1976.03615995004000030033x

HATFIELD, J. L.; SAUER, T. J.; PRUEGER, J. H. Managing soils to achieve greater water use efficiency: a review. **Agronomy Journal**, v.93, p.271-280, 2001. DOI: 10.2134/agronj2001.932271x

HEIL, C. Rapid, Multi-Component Analysis of Soybeans by FT-NIR Spectroscopy. Madison: Thermo Fisher Scientific, 2010. 3 p. (Application note: 51954). Available at: [https://tools.thermofisher.com/content/sfs/brochures/AN-51954-Rapid-Multi-omponent - Analysis-Soybeans-AN51954-EN.pdf](https://tools.thermofisher.com/content/sfs/brochures/AN-51954-Rapid-Multi-omponent-Analysis-Soybeans-AN51954-EN.pdf). Accessed on: 27 jan. 2020.

HIJMANS, R. J. **Raster**: Geographic data analysis and modeling. R package version 2.2-31. [on-line3], 2014. <http://CRAN.Rproject.org/package=raster>

JAYME-OLIVEIRA, A.; RIBEIRO JUNIOR, W. Q.; RAMOS, M. L. G.; ZIVIANI, A. C.; JAKELAITIS, A. Amaranth, quinoa, and millet growth and development under different water regimes in the Brazilian Cerrado. **Pesquisa Agropecuária Brasileira**, v. 52, n. 8, 561–571, 2017. DOI: 10.1590/s0100-204x2017000800001

JORDAN, C. F. Derivation of leaf area index from quality of light on the forest floor. **Ecology**, v. 50, p. 663–666, 1969. DOI: <https://doi.org/10.2307/1936256>

JUMRANI, K., BHATIA, V. S. Identification of drought tolerant genotypes using physiological traits in soybean. **Physiology and Molecular Biology of Plants**, v. 25, p. 697–711, 2019. DOI: 10.1007/s12298-019-00665-5

LI, M.; LIU, Y.; WANG, C.; YANG, X.; LI, D.; ZHANG, X.; XU, C.; ZHANG, Y.; LI, W.; ZHAO, L. Identification of Traits Contributing to High and Stable Yields in Different Soybean Varieties Across Three Chinese Latitudes. **Frontiers in Plant Science**, v. 10, p. 1642, 2020. DOI: 10.3389/fpls.2019.01642

MAIMAITIYIMING, M.; GHULAM, A.; BOZZOLO, A.; WILKINS, J. L.; KWASNIEWSKI, M. T. Early detection of plant physiological responses to different levels of water stress using reflectance spectroscopy. **Remote Sensing**, v. 9, n. 7, p. 745, 2017. DOI: 10.3390/rs9070745

MAIMAITIJIANG, M.; SAGAN, V.; SIDIKE, P.; HARTLING, S.; ESPOSITO, F.; FRITSCHI, F. B. Soybean yield prediction from UAV using multimodal data fusion and deep learning. **Remote Sensing of Environment**, v. 237, p. 111599, 2020. DOI: 10.1016/j.rse.2019.111599

MICASENSE. How do professional multispectral cameras differ from single-imager multispectral câmeras - RedEdge-MX 2020. Disponível em: <<http://www.micasense.com/>>. Acesso em: 25.fev.2020.

MUTAVA, R. N.; PRINCE, S. J. K.; SYED, N. H.; SONG, L.; VALLIYODAN, B.; CHEN, W.; NGUYEN, H. T. Understanding abiotic stress tolerance mechanisms in soybean: A comparative evaluation of soybean response to drought and flooding stress. **Plant Physiology and Biochemistry**, v. 86, p. 109-120, 2015. DOI: 10.1016/j.plaphy.2014.11.010

MYNENI, R. B.; HALL, F. G.; SELLERS, P. J.; MARSHAK, A. L. The interpretation of spectral vegetation indexes. **IEE Transactions on Geosciences and Remote Sensing**, v. 33, p. 481-486, 1995. <https://doi.org/10.1109/36.377948>

NAGARAJAN, D.; KALAIMAGAL, T.; MURUGAN, E. Combining ability analysis for yield component and biochemical traits in soybean [*Glycine max* (L.) Merrill]. **International Journal of Current Microbiology and Applied Sciences**, v. 6, p. 2894–2901, 2017. DOI: 10.20546/ijcmas.2017.611.341

OLAWUYI, O. J.; JONATHAN, S. G.; BABATUNDE, F. E.; BABALOLA, B. J.; YAYA, O. O. S.; AGBOLADE, J. O.; AINA, D. A.; EGUN, C. J. Accession × treatment interaction, variability and correlation studies of pepper (*Capsicum* spp.) under the influence of arbuscular mycorrhiza fungus (*Glomus clarum*) and cow dung. **American Journal of Plant Sciences**, v. 5, p. 683-690, 2014. DOI: 10.4236/ajps.2014.55083

PEREIRA, L. F.; RIBEIRO JUNIOR, W. Q.; RAMOS, M. L. G.; SANTOS, N. Z.; SOARES, G. F.; CASARI, R. A. C. N.; MULLER, O. TAVARES, C. J.; MARTINS, E. S.; RASCHER, U.; GUIMARÃES, C. A. L.; PEREIRA, A. F.; MERTZ-HENNING, L.M.; SOUSA, C. A. F. Physiological changes in soybean cultivated with soil remineralizer in the Cerrado under variable water regimes. **Pesquisa Agropecuária Brasileira**, v. 56, e01455, 2021. DOI: 10.1590/S1678-3921.pab2021.v56.01455

QIU, R. C.; WEI, S.; ZHANG, M.; SUN, H.; LI, H.; LIU, G.; LI, M. Sensors for measuring plant phenotyping: A review. **International Journal of Agricultural and Biological Engineering**, v. 11, n. 2, p. 1–17, 2018. DOI: 10.25165/j.ijabe.20181102.2696

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95-107, 1996. DOI: [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)

SANTOS, H. G.; JACOMINE, P. K. T.; DOS ANJOS, L. H. C.; DE OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; DE ALMEIDA, J. A.; ARAÚJO FILHO, J. C. de; OLIVEIRA, J. B. de; CUNHA, T. J. F. Sistema brasileiro de classificação de solos. Brasília, DF: Embrapa, 2018.

SENTELHAS, P. C.; BATTISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **The Journal of Agricultural Science**, v. 153, n. 8, p. 1394-1411, 2015. DOI:10.1017/S0021859615000313

SILVA JUNIOR, C. A.; DA NANNI, M. R.; SHAKIR, M.; TEODORO, P. E.; DE OLIVEIRA-JÚNIOR, J. F.; CEZAR, E.; GOIS, G.; DE LIMA, M.; WOJCIECHOWSKI, J. C.; SHIRATSUCHI, L. S. Soybean varieties discrimination using non-imaging hyperspectral sensor. **Infrared Physics & Technology**, v. 89, p. 338-350, 2018. DOI: 10.1016/j.infrared.2018.01.027

SILVA, E. E.; BAILO, F. H. R.; TEODORO, L. P. R.; SILVA JUNIOR, C. A.; BORGES, R. S.; TEODORO, P. E. T. UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation. **Remote Sensing Applications: Society and Environment**, v. 18, 100318, 2020. DOI: 10.1016/j.rsase.2020.100318.

SOBEJANO-PAZ, V.; MIKKELSEN, T. N.; BAUM, A.; MO, X.; LIU, S.; KÖPPL, C. J.; JOHNSON, M. S.; GULYAS, L.; GARCÍA, M. Hyperspectral and Thermal Sensing of Stomatal Conductance, Transpiration, and Photosynthesis for Soybean and Maize under Drought. **Remote Sensing**, v. 12, n. 19, 2020. DOI: 10.3390/rs12193182

SOIL SURVEY STAFF. In: Burt, R., Soil Survey Staff (Eds.), Soil Survey Field and Laboratory Methods Manual. Soil Survey Investigations Report No. 51, Version 2.0. U.S. Department of Agriculture, Natural Resources Conservation Service, 2014.

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER, A. D. Aerial Color Infrared Photography for Determining Early In-season Nitrogen Requirements in Corn. **Agronomy Journal**, v. 98, p. 968-977, 2006. DOI: <https://doi.org/10.2134/agronj2005.0200>

STEVEN, M. D. The sensitivity of the OSAVI vegetation index to Observational Parameters. **Remote Sensing of Environment**, v. 63, p. 49-60, 1998. DOI: [https://doi.org/10.1016/S0034-4257\(97\)00114-4](https://doi.org/10.1016/S0034-4257(97)00114-4)

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

USDA (United States Department of Agriculture). World Agricultural Production. Circular Series WAP 8-21, August 2021. 2021. Available online: <https://apps.fas.usda.gov/psdonline/circulars/production.pdf> (accessed on 16 August 2021).

VILLASENOR-ALVA, J.A.; GONZALEZ-ESTRADA, E. A generalization of Shapiro-Wilk's test for multivariate normality. **Commun. Stat. Theory Methods.**, 2009, 38,1870-1883. DOI: <https://doi.org/10.1080/03610920802474465>.

YAMORI, W.; KUSUMI, K.; IBA, K.; TERASHIMA, I. Increased stomatal conductance induces rapid changes to photosynthetic rate in response to naturally fluctuating light conditions in rice. **Plant, Cell & Environment**, v. 43, n. 5, p. 1230-1240, 2020. DOI: 10.1111/pce.13725

YANG, M.; HASSAN, M. A.; XU, K.; ZHENG, C.; RASHEED, A.; ZHANG, Y.; JIN, X.; XIA, X.; XIAO, Y.; HE, Z. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, 2020. DOI: 10.3389/fpls.2020.00927

YU, N.; LI, L.; SCHMITZ, N.; TIAN, L. F.; GREENBERG, J. A.; DIERS, B. W. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle-based platform. **Remote Sensing of Environment**, v. 187, p. 91-201, 2016. DOI: 10.1016/j.rse.2016.10.005

WIJewardana, C.; REDDY, K. R.; BELLALOU, N. Soybean seed physiology, quality, and chemical composition under soil moisture stress. **Food Chemistry**, v. 278, n. 1, p. 92-100, 2019. DOI: <https://doi.org/10.1016/j.foodchem.2018.11.035>

ZHAO, W.; LIU, L.; SHEN, Q.; YANG, J.; HAN, X.; TIAN, F.; WU, J. Effects of Water Stress on Photosynthesis, Yield, and Water Use Efficiency in Winter Wheat. **Water**, v. 12, n. 8, p. 1-19, 2020. DOI: 10.3390/w12082127

ZHOU, J.; ZHOU, J.; YE, H.; ALI, M. L.; NGUYEN, H. T.; CHEN, P. Classification of soybean leaf wilting due to drought stress using UAV-based imagery. **Computers and Electronics in Agriculture**, v. 175, 105576, 2020. DOI: 10.1016/j.compag.2020.105576.

2.6 Apêndice

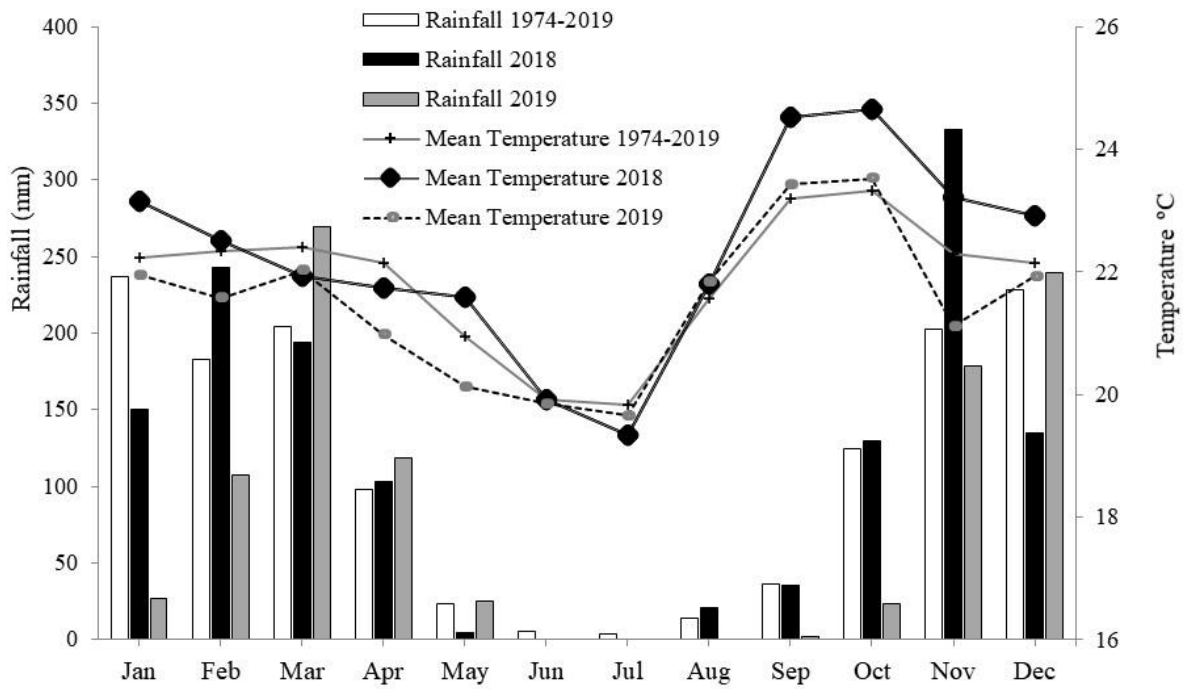


Figura 1. Precipitação e temperatura média obtidos em uma estação meteorológica automatizada localizada próxima ao experimento, nos anos de 2018 e 2019 e uma série histórica (1974 – 2019).

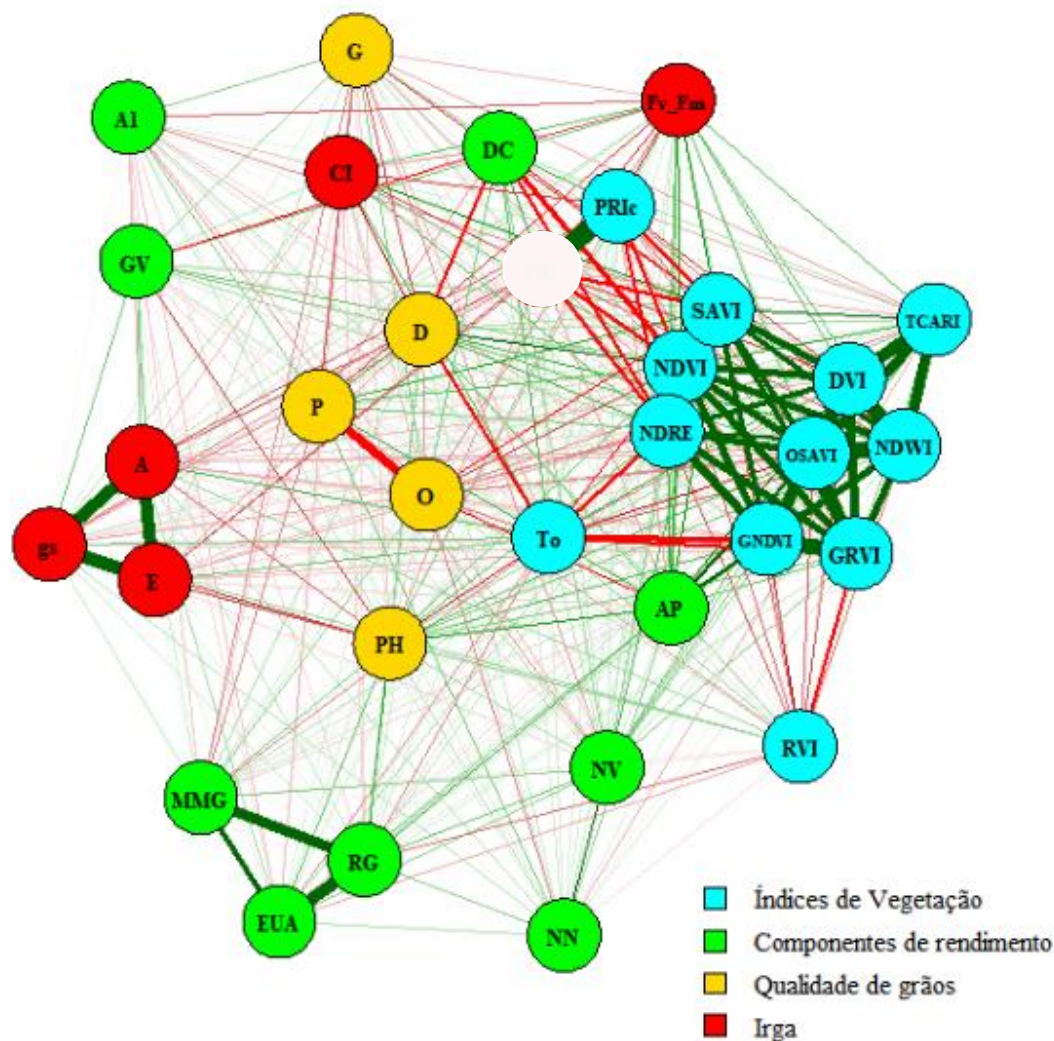


Figura 2. Rede de correlações entre índices espectrais (*Índices de vegetação + Irga*) e variáveis agrônômicas de soja (*Componentes de rendimento + Qualidade de grãos*). As linhas vermelhas representam correlações negativas e as verdes representam correções positivas. A espessura da linha é proporcional à magnitude da correlação. As linhas em destaque apresentam correlação em módulo maior que 0,6. Variáveis: Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI), Green-Red Vegetation Index (GRVI), Difference Vegetation Index (DVI), Normalized Difference Water Index (NDWI), Normalized Difference Red Edge (NDRE), (Ratio Vegetation Index (RVI), Soil Adjusted Vegetation Index (SAVI), Photochemical Reflectance Index (PRIc), Optimized Soil Adjusted Vegetation Index (OSAVI), Chlorophyll Absorption and Reflectance Index (TCARI), Relação TCARI/OSAVI (To), Índice de Reflectância Fotoquímica (PRIc), Assimilação líquida de CO₂ (A); Condutância Estomática (gs); Transpiração (E); Rendimento Quântico Máximo do Fotossistema II (Fv_Fm), Concentração Interna de CO₂ (CI), Altura de Plantas (AP), Altura Inserção Primeira Vagem (A1), Diâmetro do Coleto (DC), Número de Vagens (NV), Grão por Vagem (GV), Número de Nós (NN), Massa de Mil Grãos (MMG), Rendimento de Grãos (RG), Eficiência no Uso de Água (EUA), Teor de óleo (O); Teor de Proteína (P); Peso Hectolitro (PH); Germinação (G), e Sementes Duras (D).

Tabela 1. Médias das variáveis morfológicas, rendimento, eficiência no uso de água e qualidade grãos em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.

Cultivares	RH ^{1/}	Variáveis													
		A1	AP	DC	NN	NG	GV	PH	MMG	RG	G	EUA	O	P	D
BRS 5980IPRO	31	1.03	25.8	4.7	10.1	18.9	2.06	63.10	142.8	2338	73.3	11.20	19.1	39.5	23.0
	44	0.96	28.4	4.9	11.6	26.3	2.01	65.78	141.9	2782	92.6	8.82	19.1	39.6	2.2
	64	0.83	29.3	5.0	11.5	32.4	2.10	63.15	141.8	3271	92.3	7.20	19.0	39.0	1.0
	100	0.84	30.1	5.2	12.1	36.1	2.08	64.33	151.4	3351	93.3	4.85	19.6	38.8	0.3
BRS 7180IPRO	31	1.16	35.4	2.7	9.9	22.2	1.98	61.00	134.0	2419	88.6	9.83	21.4	38.7	5.5
	44	0.98	38.8	5.9	12.2	29.8	2.10	63.24	152.2	3026	82.0	7.05	19.7	38.5	2.3
	64	1.01	38.9	6.4	11.6	34.3	2.26	64.70	162.3	3305	69.0	5.45	20.4	37.3	4.7
	100	0.90	42.2	6.3	11.2	39.5	2.09	63.07	168.5	3431	54.0	4.08	21.3	37.0	0.2
BRS 7280RR	31	1.13	39.9	6.0	11.3	19.3	2.08	64.70	178.1	3117	86.0	12.03	20.3	40.4	6.2
	44	1.07	36.1	6.0	10.9	28.7	2.17	63.10	180.2	3628	92.0	8.82	20.7	39.1	2.2
	64	1.13	43.5	5.6	14.5	26.5	2.28	63.80	203.1	4312	87.3	7.28	19.6	39.8	0.0
	100	1.04	41.5	5.5	11.8	29.7	2.13	63.72	212.8	4342	87.0	4.86	21.0	38.9	0.7
BRS 7380RR	31	1.06	32.5	5.1	11.6	21.2	2.18	61.10	133.2	2527	93.6	10.48	19.9	39.7	0.7
	44	0.93	35.5	5.5	12.8	30.6	2.18	61.07	141.3	3052	91.3	7.90	21.3	38.0	0.2
	64	0.96	37.4	5.6	13.1	36.2	2.20	62.32	158.0	3474	83.3	5.96	22.1	38.0	0.0
	100	0.95	37.4	5.8	13.9	47.6	2.16	62.00	173.7	3751	87.3	4.36	22.1	37.6	0.0
M 6410IPRO	31	0.99	32.0	4.9	11.1	17.6	2.09	62.02	139.1	2604	83.3	10.91	20.6	40.3	14.5
	44	0.94	32.1	4.9	11.1	23.0	2.25	62.32	148.1	3286	95.6	8.48	20.8	38.9	1.2
	64	0.95	34.3	5.1	12.4	30.8	2.22	61.60	165.4	3544	90.0	6.18	22.9	36.7	0.0
	100	0.88	35.2	5.0	12.0	33.2	2.08	63.98	183.3	4013	86.0	4.40	22.6	36.3	0.0
NA 5909GR	31	0.91	25.5	6.7	10.6	19.9	2.05	62.83	169.7	2910	76.0	11.66	21.9	37.5	19.8
	44	0.85	28.2	5.7	11.0	27.4	1.86	63.93	167.6	3419	94.6	8.52	21.1	37.9	1.5
	64	0.87	30.0	5.6	12.1	29.9	1.87	63.73	192.5	4055	90.3	6.82	21.4	37.5	0.2
	100	0.81	31.6	6.1	12.6	41.1	1.82	65.95	205.4	4261	88.6	4.82	21.8	37.5	1.8
Média		0.96	34.2	6.7	11.80	29.3	2.10	63.19	164.4	3342	85.7	7.40	20.8	38.4	38.4
Erro Padrão		0.02	1.04	0.93	0.22	1.56	0.02	0.28	4.75	119.46	1.94	1.02	0.23	0.23	0.23
CV		1.01	1.49	6.76	0.92	2.60	0.58	0.22	1.41	1.75	1.11	3.48	0.54	0.30	0.30

^{1/}RH: Regimes hídricos (31, 44, 64 e 100% da reposição ETc - RH1, RH2, RH3 e RH4 respectivamente); A1: altura inserção primeira vagem (cm); AP: altura de planta (cm); DC: diâmetro do coleto (mm); NN: número de nós; NV: número de vagens; GV: grãos por vagem; PH: peso hectolitro; MMG: massa de mil grãos (g); RG: rendimento de grãos (kg ha⁻¹); G: germinação (%); EUA: eficiência no uso da água; O: óleo (%); P: proteína (%); D: sementes duras (%); CV: coeficiente de variação (%).

Tabela 2. Médias das variáveis de índices de vegetação (câmara multiespectral), trocas gasosas e rendimento quântico máximo do fotossistema II em seis cultivares de soja sob quatro regimes hídricos nas safras de 2018 e 2019.

Cultivares	RH ^{1/}	Variáveis																
		NDVI	SAVI	DVI	GNDVI	NDRE	TCARI	OSAVI	TO	PRIC	RVI	GRVI	NDWI	A	g _s	E	Fv/Fm	CI
BRS 5980IPRO	31	0.34	0.23	0.14	0.55	0.14	0.16	0.28	0.64	0.30	2.78	3.61	-0.21	4.5	0.05	2.1	0.79	232
	44	0.41	0.27	0.17	0.58	0.18	0.17	0.34	0.58	0.32	3.88	4.14	-0.16	10.0	0.11	2.6	0.78	216
	64	0.46	0.31	0.19	0.60	0.20	0.19	0.38	0.51	0.32	4.37	4.37	-0.12	17.8	0.36	5.3	0.81	261
	100	0.51	0.34	0.20	0.61	0.22	0.21	0.42	0.58	0.33	5.26	4.70	-0.07	19.7	0.35	5.0	0.81	256
BRS 7180IPRO	31	0.42	0.30	0.19	0.58	0.19	0.18	0.35	0.66	0.33	2.91	4.27	-0.13	3.7	0.06	2.6	0.75	241
	44	0.49	0.36	0.24	0.61	0.23	0.21	0.43	0.61	0.35	1.27	5.01	-0.05	10.9	0.18	3.5	0.78	226
	64	0.57	0.41	0.27	0.62	0.25	0.26	0.49	0.55	0.35	3.03	4.75	0.00	18.3	0.33	5.3	0.80	249
	100	0.76	0.53	0.34	0.69	0.31	0.33	0.64	0.52	0.34	3.66	5.76	0.18	19.9	0.36	5.1	0.82	254
BRS 7280RR	31	0.39	0.26	0.16	0.58	0.16	0.17	0.32	0.63	0.30	3.43	3.99	-0.19	10.0	0.07	2.3	0.79	184
	44	0.44	0.30	0.19	0.60	0.20	0.18	0.37	0.58	0.34	4.64	4.47	-0.13	15.3	0.15	3.2	0.80	204
	64	0.50	0.35	0.22	0.61	0.22	0.22	0.43	0.53	0.33	5.39	4.69	-0.08	20.7	0.33	5.2	0.82	248
	100	0.56	0.38	0.23	0.62	0.23	0.25	0.47	0.58	0.32	4.35	4.85	-0.02	21.2	0.35	5.2	0.83	251
BRS 7380RR	31	0.37	0.26	0.16	0.55	0.17	0.17	0.31	0.68	0.31	3.33	3.77	-0.17	5.3	0.10	2.4	0.78	188
	44	0.44	0.31	0.20	0.58	0.20	0.19	0.38	0.64	0.35	4.98	4.31	-0.09	12.7	0.17	3.5	0.80	217
	64	0.48	0.34	0.22	0.59	0.21	0.22	0.41	0.57	0.34	5.06	4.35	-0.07	18.8	0.33	5.1	0.80	257
	100	0.64	0.44	0.28	0.61	0.24	0.32	0.54	0.65	0.34	3.23	4.74	0.09	20.7	0.36	5.1	0.81	250
M 6410IPRO	31	0.39	0.26	0.16	0.56	0.17	0.16	0.33	0.61	0.30	3.63	3.89	-0.16	6.9	0.07	2.2	0.78	283
	44	0.45	0.30	0.19	0.60	0.22	0.17	0.37	0.56	0.34	3.42	4.68	-0.12	13.9	0.18	2.9	0.79	216
	64	0.49	0.34	0.21	0.61	0.23	0.19	0.41	0.50	0.34	3.70	4.71	-0.09	19.0	0.29	4.6	0.82	256
	100	0.55	0.38	0.23	0.63	0.25	0.22	0.46	0.56	0.34	1.46	5.26	-0.03	20.9	0.36	5.2	0.82	251
NA 5909GR	31	0.34	0.22	0.13	0.56	0.15	0.15	0.28	0.60	0.29	2.75	3.67	-0.23	7.2	0.06	3.6	0.80	233
	44	0.41	0.27	0.16	0.59	0.19	0.16	0.34	0.56	0.33	3.80	4.22	-0.18	14.0	0.15	3.2	0.82	222
	64	0.48	0.32	0.19	0.61	0.21	0.20	0.39	0.54	0.34	4.53	4.48	-0.12	20.4	0.31	4.7	0.83	251
	100	0.53	0.35	0.21	0.63	0.23	0.21	0.43	0.55	0.34	3.86	4.87	-0.07	21.1	0.36	5.2	0.84	255
Média		0.33	0.20	0.60	0.21	0.20	0.40	0.58	0.33	4.0	3.70	4.48	-0.09	15.9	0.22	4.0	0.80	237
Erro Padrão		0.02	0.01	0.01	0.01	0.01	0.01	0.02	0.01	0.01	0.01	0.01	0.02	0.68	0.03	0.2	0.01	4.94
CV		2.03	2.13	2.29	0.52	1.84	2.33	2.07	0.84	0.52	0.94	0.81	1.01	1.86	5.67	3.0	2.19	1.02

^{1/} RH: regimes hídricos (31, 44, 64 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente); NDVI: Difference Vegetation Index; SAVI: Soil Adjusted Vegetation Index; DVI: Difference Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; NDRE: Red Edge Normalized Difference; TCARI: The Transformed Chlorophyll Absorption and Reflectance Index; OSAVI: Optimized Soil Adjusted Vegetation Index; TO: TCARI/OSAVI Ratio; PRIC: Photochemical Reflectance Index; RVI: Ratio Vegetation Index; GRVI: Green-Red Vegetation Index; NDWI: Normalized Difference Water Index; A: Taxa fotossintética ($\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$); g_s: Condutância estomática ($\mu\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$); E: Transpiração ($\text{mmol H}_2\text{O m}^{-2} \text{ s}^{-1}$); Fv/Fm: Rendimento Quântico Máximo do Fotossistema II; CI: Concentração interna de carbono. CV: Coeficiente de variação (%).

Tabela 3. Correlações canônicas e primeiros pares canônicos estimados entre variáveis espectrais (*Índices de vegetação*) e variáveis agrônômicas (*Componentes de rendimento + Qualidade de grãos*) e do IRGA em soja.

Variáveis	Pares canônicos		
	1º	1º	1º
NDVI	71.25	48.11	8.03
SAVI	-10.16	-34.94	-1.70
NDWI	-40.61	-5.34	-3.28
DVI	-35.48	-8.80	-6.52
RVI	0.04	0.14	0.00
GRVI	3.14	-0.48	0.20
GNDVI	-70.78	-28.54	-3.12
NDRE	-43.89	-21.90	-9.39
TCARI	72.25	2.99	-1.40
OSAVI	11.44	30.22	8.66
To	-18.70	-20.54	0.73
PRIC	-5.84	-1.81	-83.20
	A1 (0.77)	PH (0.13)	E (0.05)
	AP (0.02)	G (0.06)	gs (-0.96)
	DC (-0.10)	D (0.43)	A (0.02)
	NN (-0.07)	O (0.21)	Fv/Fm (0.94)
	NV (0.01)	P (-0.35)	CI (0.00)
	GV (-0.08)	--	--
	MMG (0.02)	--	--
	RG (0.00)	--	--
	EUA (-0.14)	--	--
Correlação	0.69	0.71	0.98
Valor <i>p</i>	< 0.01	< 0.01	< 0.01
Importância relativa (%)	41.01	58.35	96.79

Normalized Difference Vegetation Index (NDVI), Soil Adjusted Vegetation Index (SAVI), Normalized Difference Water Index (NDWI), Difference Vegetation Index (DVI), Ratio Vegetation Index (RVI), Green-Red Vegetation Index (GRVI), Green Normalized Difference Vegetation Index (GNDVI), Normalized Difference Red Edge (NDRE), Chlorophyll Absorption and Reflectance Index (TCARI), Optimized Soil Adjusted Vegetation Index (OSAVI), Relação TCARI/OSAVI (To), Photochemical Physiological Reflectance Index (PRIC), Assimilação líquida de CO₂ (A); Condutância Estomática (g_s); Transpiração (E); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm), Índice de Reflectância Fotoquímica (PRI), Concentração Interna de Carbono (CI), Altura de Plantas (AP), Altura Inserção Primeira Vagem (A1), Diâmetro do Coleto (DC), Número de Vagens (NV), Grão por Vagem (GV), Número de Nós (NN), Massa de Mil Grãos (MMG), Rendimento de Grãos (RG), Eficiência no Uso de Água (EUA), Teor de óleo (O); Teor de Proteína (P); Peso Hectolitro (PH); Germinação (G), e Sementes Duras (D).

Capítulo 3 - Respostas fisiológicas, agronômicas e espectrais de genótipos de trigo submetidos a estresse hídrico no Cerrado

Resumo - A seleção de genótipos de trigo tolerantes à seca e com maior eficiência no uso de água é uma prioridade de pesquisa, especificamente em regiões onde ocorre precipitações pluviométricas irregulares ou em locais onde as mudanças climáticas devem resultar em redução na disponibilidade de água. O objetivo deste trabalho foi avaliar as respostas fisiológicas, espectrais e agronômicas de genótipos de trigo ao estresse hídrico, no Cerrado. Os experimentos foram conduzidos no período de maio a setembro nos anos de 2018 e de 2019 utilizando o delineamento experimental em blocos casualizados, em esquema de parcelas subdivididas, com três repetições. As parcelas foram compostas de dezoito genótipos de trigo: BRS 254; BRS 264; CPAC 01019; CPAC 01047; CPAC 07258; CPAC 08318; CPAC 9110; BRS 394 (biotipos irrigados) e Aliança; BR 18 (Terena); BRS 404; MGS Brilhante; PF 020037; PF 020062; PF 120337; PF 368; PF 080492; TBIO Sintonia (biotipos de sequeiro). Utilizou-se um sistema de irrigação com uma barra com aspersores com diferentes vazões, criando-se um gradiente de água. As subparcelas corresponderam a quatro regimes hídricos: 22, 43, 81 e 100% da reposição da evapotranspiração da cultura (ET_c). A condição de estresse hídrico afetou negativamente as trocas gasosas, os índices de vegetação e o rendimento dos grãos. Sob estresse, observou-se maior eficiência no uso da água e maior massa de raízes. Índices espectrais são importantes na divergência dos genótipos e os índices baseados na banda do infravermelho próximo são relacionados com respostas fisiológicas e agronômicas. O índice de tolerância à seca indicou os genótipos Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492 como mais tolerantes à seca e os genótipos BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia como os mais afetados pela disponibilidade de água.

Palavras-chave: *Triticum aestivum*, índices de vegetação, trocas gasosas, tolerância à seca, automação.

3.1. Introdução

O trigo (*Triticum aestivum* L.) é a segunda cultura mais cultivada no mundo, com uma área cultivada estimada em cerca de 200 milhões de hectares (ZÖRB et al., 2018). O Brasil tem uma demanda anual de cerca de 12 milhões de toneladas de grãos de trigo, mas produz menos da metade de suas necessidades e importa o restante (PEREIRA et al., 2019). Para reduzir a dependência externa e os gastos com importação de trigo, é importante buscar alternativas para aumentar a produtividade das culturas e incluir novas áreas.

O Cerrado tem sido uma alternativa para o cultivo de trigo de sequeiro ou irrigado (SOARES et al., 2021) por apresentar condições climáticas e edáficas favoráveis ao cultivo. No entanto, no cultivo de sequeiro, há ocorrência de chuvas irregulares e períodos prolongados de estiagem, conhecidos como 'veranicos' (CATTELAN e DALL'AGNOL, 2018), são comuns nessa região.

Os efeitos da deficiência hídrica nas plantas podem ser minimizados por meio de manejo adequado (Wang et al., 2017) e técnicas como o plantio direto e por meio da tolerância genética. Para se estudar a tolerância genética das plantas, é necessário identificar genótipos que possam manter ou reduzir minimamente seu potencial produtivo e qualidade de grãos em condições de baixa disponibilidade hídrica (PEREIRA et al., 2019). Portanto, aumentar a tolerância à seca em genótipos de trigo é uma solução sustentável e econômica para aumentar a produção em ambientes e épocas com limitações hídricas (LI et al., 2021), sem a necessidade do uso de recursos hídricos naturais.

A sobrevivência das plantas sob seca depende de vários mecanismos atuando simultaneamente, entre eles: redução do ciclo, abertura estomática e taxa de transpiração e o desenvolvimento de antioxidantes que mantêm ajustes osmóticos em nível celular (AHMED et al., 2020). Conseqüentemente, podem ocorrer alterações morfofisiológicas que diminuem a produtividade das culturas (LIU et al., 2016).

Genótipos de plantas tolerantes ao estresse hídrico podem ser identificados por meio de uma combinação de variáveis, a saber: eficiência no uso da água (ZHAO et al., 2020), índices de tolerância à seca (SOARES et al., 2021), componentes de rendimento (ANWAAR et al., 2020), índices fisiológicos (OUYANG et al., 2017; AHMED et al., 2020) e índices de vegetação (espectrais) (ANDEREGG et al., 2020; YANG et al., 2020), que podem estar correlacionados com o rendimento e a qualidade dos grãos (MEENA et al., 2019).

O uso de sensores multiespectrais acoplados a aeronaves fornece medições de comprimento de onda na faixa visível (VIS; ~ 400-700 nm) e infravermelho próximo (NIR; ~ 700-1.200 nm) do espectro eletromagnético, o que possibilita o cálculo de diversos índices de vegetação (QIU et al., 2018), para a seleção rápida e não destrutiva de genótipos de trigo tolerantes à seca (KHADKA et al., 2020) com alta precisão (HU et al., 2020). As características multiespectrais derivadas das bandas NIR, vermelho e verde possuem uma forte relação com a biomassa de trigo, eficiência do uso da água, fotossíntese e rendimento de grãos (YANG et al., 2020).

Portanto, a caracterização de genótipos quanto à tolerância ao estresse hídrico em cultivo de sequeiro e com maior eficiência no uso da água em cultivo irrigado sob condições de Cerrado (SOARES et al., 2021) é de suma importância para aumentar a produtividade e qualidade dos grãos.

A hipótese deste trabalho é que as respostas fisiológicas não destrutivas do trigo, assim como os índices vegetativos, estão relacionadas com a disponibilidade hídrica do solo e podem ser utilizados para discriminar genótipos tolerantes ao estresse hídrico. O objetivo deste trabalho foi avaliar as respostas fisiológicas, espectrais e agrônômicas de genótipos de trigo biotipos sequeiro e irrigado, submetidos a diferentes regimes hídricos, no Cerrado.

3.2. Material e Métodos

Os experimentos foram conduzidos em Planaltina, DF, Brasil (15°35'30" S e 47°42'30" W, e altitude de 1006 m), entre maio e setembro de 2018 e 2019, que coincide com a estação seca da região, permitindo controlar o fornecimento de água às plantas.

O clima da região é classificado como Aw (Koeppen-Geiger) - Tropical, com chuvas concentradas no verão (outubro a abril) e um período de estiagem durante o inverno (maio a setembro), com precipitação média anual entre 1200 e 1500 mm, concentrado de novembro a março. Os dados de precipitação e temperatura do ar da área experimental foram coletados em 2018 e 2019 (Figura 1) em uma estação meteorológica próxima ao experimento. A área experimental foi cultivada nos últimos quatro anos com trigo sob diferentes regimes hídricos no inverno e pousio no verão.

O solo é classificado como Latossolo Vermelho distroférrico (SANTOS et al., 2018), o qual apresentou as seguintes características físico-químicas, determinadas na profundidade de 0 a 20 cm: pH (CaCl₂) de 5,7; P de 11 mg dm⁻³; K de 186 mg dm⁻³; Ca de 5,77 cmol_c dm⁻³; Mg de 1,83 cmol_c dm⁻³; Al de 0,02 cmol_c dm⁻³ e granulometria de 46, 10 e 44 dag kg⁻¹ de argila, silte e areia, respectivamente.

A curva de retenção de água do solo ajustado pelo modelo de Van Genuchten (1980) apresentou os seguintes parâmetros: conteúdo de água residual (θ_s) 0,0839 cm³ cm⁻³, conteúdo de água na saturação (θ_s) 0,5500 cm³ cm⁻³ e os parâmetros α (1,892 kPa⁻¹) e n (1,2390). A umidade na capacidade de campo foi de 0,3423 cm³ cm⁻³.

O delineamento experimental foi em blocos casualizados em esquema de parcelas subdivididas, com três repetições. As parcelas foram compostas por dezoito genótipos de trigo: BRS 254; BRS 264; CPAC 01019; CPAC 01047; CPAC 07258; CPAC 08318; CPAC 9110; BRS 394 (biotipos irrigados) e Aliança; BR 18 (Terena); BRS 404; MGS Brilhante; PF 020037; PF 020062; PF 120337; PF 368; PF 080492; TBIO Sintonia (biotipos de sequeiro). As subparcelas corresponderam a quatro regimes hídricos (RH). Em 2018, 197,15 mm, 238,34

mm, 498,18 mm e 562,2 mm foram aplicados durante o ciclo da cultura, correspondendo a RH1, RH2, RH3 e RH4, respectivamente. Em 2019, 189,5 mm, 254,47 mm, 438,55 mm e 541,43 mm foram aplicados, correspondendo a RH1, RH2, RH3 e RH4, respectivamente. Em 2018 e 2019, os regimes hídricos usados foram equivalentes a 22%, 43%, 81% e 100% da reposição da evapotranspiração da cultura (ET_c).

As cultivares biotipos de sequeiro foram Brilhante, Aliança, TBIO Sintonia e BR18 (todos materiais tradicionais), e BRS 404 (registrada em 2014). As linhagens de sequeiro desenvolvidas para a região do Cerrado foram PF020037 [(presença de grande enceramento nas folhas e colmo, segundo Ribeiro Junior et al. (2006)], PF020062 (mesmo cruzamento do genótipo anterior, mas sem a produção de cera). O biotipo de sequeiro PF 080492 foi desenvolvido para o Sul do Brasil e devidamente adaptado à região do Cerrado. Os cultivares irrigados foram BRS 254, BRS 264 (materiais tradicionais) e BRS 394 (registrada em 2014) e em fase experimental para lançamento, os biotipos irrigados CPAC 01019; CPAC 01047; CPAC 07258; CPAC 08318 e CPAC 9110;

As irrigações de nível mais alto foram realizadas conforme descrito no programa de monitoramento de irrigação no Cerrado (EMBRAPA, 2011), isto é, através da reposição da evapotranspiração, utilizando-se indicadores agrometeorológicos da região, tipo de solo e data de emergência total das plantas. O programa estima a evapotranspiração de referência com base na equação proposta por Penman-Monteith (ALLEN et al., 1998). A frequência de irrigação foi realizada aproximadamente a cada 5 dias, de acordo com as condições climáticas e a fase fenológica da cultura. Para calcular a quantidade de água aplicada, em cada irrigação, foram montadas duas fileiras de coletores paralelos à linha de irrigação para medir o volume de água aplicada.

O histórico dos últimos 4 anos de cultivo da experimental é de trigo sob diferentes regimes hídricos no inverno e pousio no verão. A área foi dessecada com glifosato na dose de

1440 g.e.a ha⁻¹ aos 20 dias antes da semeadura. A semeadura foi realizada mecanicamente no dia 22 de maio de 2018 e em 23 de maio de 2019, em sistema plantio direto, utilizando-se 90 sementes por metro, semeadas a uma profundidade de 3 cm. Na adubação de base utilizou-se 400 kg ha⁻¹ de adubo formulado 04-30-16 (N, P₂O₅, K₂O) e aos 25 DAE (dias após a emergência) foi realizada a adubação nitrogenada em cobertura, feita a lanço, na dose de 90 kg ha⁻¹ N, na forma de ureia.

Como tratamentos fitossanitários, visando o controle de vaquinha (*Diabrotica speciosa*) foram realizadas aplicações do inseticida tiametoxam + lambda-cialotrina nas doses de 14,1 g + 10,6 g ha⁻¹ aos 5 e aos 18 dias após a emergência do trigo (DAE), no ano de 2018 e as 8 e 22 DAE, no ano de 2019. Aos 36 e 38 DAE, nos anos de 2018 e 2019 respectivamente, no primeiro nó visível e com o segundo nó perceptível, realizou a aplicação do redutor de crescimento trinexapac-ethyl na dose de 125 g ha⁻¹. A aplicação do herbicida metsulfurom metílico na dose de 4 g ha⁻¹ foi realizada aos 15 DAE para controle das plantas daninhas, em ambos os anos.

Em ambos os experimentos, aplicou-se a uma lâmina de água homogênea nos primeiros 35 DAE, com a reposição média de 150 mm de água, para se obter um estande homogêneo de plantas. Após esse período, foi adotada a metodologia denominada “line source” (HANKS et al., 1976), modificada pela introdução de uma barra de irrigação (JAYME-OLIVEIRA et al., 2017). Utilizaram-se aspersores com vazão decrescente do meio para a borda da barra, a fim de produzir um gradiente de déficit hídrico. Os regimes hídricos (RH) foram obtidos através da barra de irrigação (IrrigaBrasil modelo 36/42), de 20 m de largura em cada lado, conectada a um TurboMaq 75/GB autopropulsor, com velocidade ajustável de acordo com a quantidade de água a ser aplicada.

Cada unidade experimental foi composta por um genótipo, com 18,0 m de comprimento, formada por 8 linhas de cultivo, com espaçamento de 0,17 m. Cada regime

hídrico (RH) constituiu-se de uma subunidade experimental de 2,0 m de comprimento, formada por 8 linhas, com espaçamento de 0,17 m, com a área útil constituída pelas seis linhas centrais, descartando-se as bordaduras, sendo 2 m de cada lado. Assim, em 18 m de comprimento da parcela, foram alocados os quatro níveis de água.

Para a caracterização das variáveis de trocas gasosas foram avaliados aos 75 DAE, na fase fenológica de florescimento, a assimilação líquida de CO₂ (A), condutância estomática (g_s) e a taxa de transpiração (E). Essa avaliação foi realizada das 8:30 às 12:30, sob uma irradiância de 1200 μmol de fótons $\text{m}^{-2} \text{s}^{-1}$ e concentração externa de CO₂ (C_a) de 400 $\mu\text{mol mol}^{-1}$ de ar, com um equipamento de sistema de troca de gás de fluxo aberto portátil, utilizando-se um IRGA (Infra-red gas analyser, modelo LI-6400xt LI-COR Inc., Lincoln, NE). O rendimento quântico máximo do fotossistema II (F_v/F_m) foi medido com um fluorômetro portátil modulado acoplado ao IRGA. As avaliações foram realizadas em folhas adaptadas ao escuro, por pelo menos 3h, e a avaliação foi realizada após as 22h30, para que os centros de reação estivessem totalmente abertos (todos os aceitadores primários de elétrons oxidados) com mínima perda de calor. Nesta condição, foi possível estimar a fluorescência inicial (F_0), fluorescência máxima (F_m) e rendimento quântico potencial do fotossistema II [$F_v/F_m = (F_0 - F_m)/F_m$] (GENTY et al., 1989). Para as avaliações de trocas gasosas e do rendimento quântico máximo do fotossistema II foram feitas três avaliações em cada subparcela nas folhas bandeira totalmente desenvolvidas e fisiologicamente maduras, com umidade relativa entre 65 e 70%, temperatura entre 20 e 25 °C (noite/dia).

Os teores de clorofila a e b foram medidos utilizando-se o medidor portátil de clorofila ClorofiLOG (CFL-1030, Falker) que fornece medições relativas (0 a 100) do total de clorofila, mas que se correlaciona linearmente com o teor de clorofila total (RIGON et al., 2012).

A avaliação dos índices de vegetação (IV) foi realizada também no estágio do florescimento utilizando-se uma câmera multiespectral modelo Micasense RedEdge acoplada

em um veículo aéreo não tripulado (VANT) de asas rotativas. Esta câmera captura imagens em cinco diferentes bandas espectrais, denominadas blue (intervalo: 465-485 nm; Largura: 20 nm), green (intervalo: 550-570 nm; largura: 20 nm), red (intervalo: 663-673nm; largura:10 nm), red edge (intervalo: 712-722nm; largura: 10nm), near infra-red (NIR) (intervalo: 820-860 nm; largura: 40 nm), com resolução óptica de 1280 x 960 pixels e imagens gravadas em RAW12 bits (MICASENSE, 2020). O voo foi realizado a 45 m de altura, às 10:00 h.

Os mapas de reflectância foram calculados a partir da geração dos mosaicos no software Pix4D Mapper (v5.4.6, Pix4D, Lausanne, Suíça), com base nas imagens do painel (MicaSense, modelo RP04 CRP) de calibração antes e após cada voo, além da captura da radiação no momento de cada imagem.

Posteriormente, as imagens foram processadas no software R utilizando o pacote raster, e os seguintes índices vegetativos foram extraídos: Normalized Difference Vegetation Index - NDVI (ROUSE et al., 1973); Green Normalized Difference Vegetation Index - GNDVI (DAUGHTRY et al., 2000); Green-Red Vegetation Index - GRVI (SRIPADA et al., 2006); Difference Vegetation Index - DVI (TUCKER, 1979); Normalized Difference Red Edge - NDRE (GITELSON e MERZLYAK 1994); Soil Adjusted Vegetation Index - SAVI (RONDEAUX et al., 1996); Photochemical Physiological Reflectance Index - PRI (GAMON et al., 1992); Optimized Soil Adjusted Vegetation Index - OSAVI (STEVEN, 1998); Chlorophyll Absorption and Reflectance Index - TCARI (HABOUDANE et al., 2002); TCARI/OSAVI - TO ratio (HABOUDANE et al., 2002).

No florescimento, foi realizada a amostragem do solo - para caracterização da massa de raízes - e da parte aérea dos genótipos de trigo. Para a amostragem radicular, utilizou-se um trado tipo “caneca”, com bordas afiadas, e dimensões de 9,8 cm de diâmetro interno e 20 cm de comprimento, amostrando 1508 cm³ de solo com raízes por subunidade experimental, em áreas homogêneas, posicionado o trado no centro da linha de cultivo, sendo que a parte aérea

correspondente à área do trado foi retirada com o auxílio de uma faca. O trado é feito em aço inoxidável e possui uma haste de ferro que facilita a rotação e a aplicação de força. Esse método de amostragem foi adaptado de Ratke et al. (2014).

As amostras de raízes com o solo foram armazenadas em sacos plásticos e a parte aérea em sacos de papel. Em laboratório, determinou-se a massa de solo com raízes e uma subamostra de 100 g foi utilizada para determinar a umidade do solo. As amostras foram armazenadas em câmaras frigoríficas com temperaturas de -5°C , pelo menor tempo possível, até a separação das raízes do solo, evitando-se perdas de massa ou desidratação das raízes. As raízes foram separadas do solo através de uma tríplice lavagem com água, em peneira com malha de $500\ \mu\text{m}$ e, posteriormente, separaram-se as raízes de outros materiais orgânicos.

As raízes e a parte aérea foram acondicionadas em sacos de papel e colocadas em estufa, com circulação de ar forçado, a uma temperatura de 60°C por 72 horas para a obtenção da massa seca. Os resultados foram expressos em massa seca de raiz por massa de solo e relação da parte aérea/raiz.

Na colheita do trigo, avaliou-se o rendimento de grãos (RG) na área útil de cada subunidade experimental, e a massa de 1000 grãos (MMG). Os valores do rendimento de grãos e da massa de 1000 grãos foram expressos padronizando-se o teor de água dos grãos para 13% em base úmida.

A eficiência no uso de água (EUA) foi calculada através da relação entre rendimento de grãos e demanda hídrica da cultura (HATFIELD et al., 2001). A eficiência intrínseca do uso da água (iEUA) foi calculada pela razão entre a assimilação líquida de CO_2 e a condutância estomática (A/g_s). O índice de tolerância à seca foi calculado pela fórmula: $\text{DRI} = (Y_s / Y_n) / (M_s / M_n)$, onde: Y_s e Y_n são os rendimentos do genótipo sob estresse e sem estresse, respectivamente. M_s e M_n são a média da produtividade de todos os genótipos sob estresse e sob irrigação plena, respectivamente (FISCHER e MAURER, 1978).

Os dados foram submetidos à análise de variância multivariada conjunta por safra, baseado na análise de decomposição em valores singulares (SVD). Os resíduos foram testados para normalidade multivariada usando o teste generalizado de Shapiro-Wilk (VILLASENOR-ALVA e GONZALEZ-ESTRADA, 2009) e para homogeneidade de matrizes de covariância usando o teste Box-M (BOX, 1949). Os genótipos foram agrupados com base na distância de Mahalanobis usando o método de Ward. O critério de Mojena (1977) foi utilizado para definir o ponto de corte no dendrograma, e a importância relativa (proporção) das variáveis na distância entre os genótipos foi determinada pelo critério de Singh (1981). Em dois anos, as médias dos tratamentos (combinações de genótipos e regimes hídricos) foram analisadas graficamente em um *biplot* baseado na decomposição de valores singulares (GABRIEL, 1971). A análise de correlação de Pearson (teste t, $p < 0,05$) foi realizada com os resíduos. Modelos de regressão foram ajustados para desvendar o efeito do regime hídrico nas variáveis de resposta e os valores médios das variáveis foram apresentados em tabela. As análises estatísticas foram realizadas utilizando o software R v3.6.1.

3.3. Resultados e Discussão

Os valores médios das características morfofisiológicas e espectrais analisadas na cultura do trigo de acordo com os grupos de genótipos e regimes hídricos nas safras 2018 e 2019 são apresentados nas Tabelas 1 e 2. Em geral, as alterações na disponibilidade hídrica afetaram as características morfofisiológicas, espectrais e a produtividade dos genótipos de trigo estudados.

Na análise de variância multivariada conjunta, foram obtidas diferenças significativas, para as fontes de variação genótipos ($p < 0,01$), regimes hídricos ($p < 0,01$), ano de cultivo ($p < 0,01$) e para a interação genótipos x regimes hídricos ($p < 0,01$). Não houve significância (p

= 1) para a interação genótipos x regimes hídricos x ano de cultivo. A significância da interação genótipo x regime hídrico mostrou que os genótipos responderam diferentemente à disponibilidade hídrica. Isso indica variabilidade genética entre os genótipos de trigo quanto às variáveis estudadas, fator essencial para a realização de estudos de distância genética. A variabilidade dos genótipos em resposta à disponibilidade hídrica foi relatada por Silva et al. (2020) em estudos com biótipos de trigo irrigado e de sequeiro, triticale e feijão comum.

Na Figura 2 pode-se identificar três grupos de genótipos formados a partir do agrupamento na análise de cluster. O Grupo 1 foi constituído de seis genótipos (33,33%) (Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492); o grupo 2 possui quatro genótipos (22,22%) (BR 18_Terena; MGS Brilhante; PF 020037; PF 120337) e o grupo 3 possui oito genótipos (44,45%) (BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia). Os genótipos mais semelhantes foram Aliança e BRS 254, e os que mais diferiram entre si foram PF 020037 e PF 120337. Soares et al. (2021) trabalhando com dez genótipos de trigo e Silva et al. (2021) trabalhando com dezenove genótipos de quinoa, na região do Cerrado brasileiro no mesmo período de plantio (maio a setembro), também mostraram genótipos adaptados a diferentes regimes hídricos.

Os genótipos do grupo 1 apresentaram maior índice de resistência à seca (DRI= 1,01) do que os materiais do grupo 3 (DRI = 0,93), com valores intermediários no grupo 2 (DRI = 0,95) (Tabela 2). Esse resultado era esperado, uma vez que os genótipos classificados no grupo 1, com exceção do CPAC 01019 e BRS 254, são biótipos de sequeiro, enquanto os membros do grupo 3, com exceção dos genótipos PF 100368 e TBIO Sintonia, são biótipos para o cultivo irrigado, que geralmente apresentam baixo DRI, pois foram desenvolvidos para ambientes sem restrição hídrica. O estudo realizado por Soares et al. (2021) confirmam este resultado de agrupamento, em que os genótipos de sequeiro (Aliança, BRS 404 e MGS Brilhante)

apresentaram DRI superior aos genótipos irrigados (BRS 394, BRS 254 e BRS 264) em dois anos de cultivo.

Os índices vegetativos foram responsáveis por 97% da divergência total observada entre os genótipos sob influência do estresse hídrico (Tabela 3). Índices baseados na banda do infravermelho próximo (OSAVI (33%), SAVI (33%), NDRE (11%), DVI (11%), GNDVI (3%) e NDVI (1%) foram mais fortemente associados com a diferenciação de grupos de genótipos. Além disso, foram as variáveis mais afetadas pelo estresse hídrico. Isso indica a possibilidade de utilização de índices vegetativos como uma ferramenta rápida e não destrutiva para diferenciar genótipos de trigo.

No geral, esses resultados são consistentes com dados de outros autores que obtiveram índices espectrais baseados em NIR com alta precisão e eficiência na seleção de genótipos de trigo mais produtivos sob estresse hídrico (BOWMAN et al., 2015; HU et al., 2020), enquanto que os índices baseados na faixa visível são mais fortemente correlacionados com o crescimento da planta (PREY e SCHMIDHALTER 2019; YANG et al., 2020).

Além disso, Hu et al. (2020) relataram que índices espectrais coletados por câmeras acopladas a aeronaves mostram uma correlação mais forte com o rendimento de grãos do que os índices obtidos por métodos proximais, indicando maior precisão, velocidade e ganhos de escala.

A decomposição em valores singulares das médias de combinações de regimes hídricos e grupos de genótipos reteve 86% da variabilidade total na primeira coordenada principal (Figura 3). Há um forte contraste nas respostas entre os grupos de genótipos que receberam RH1 (22% da reposição da Etc) em comparação com os mesmos grupos no RH4 (100% da reposição da ETC). Isso significa que o processo de seleção deve ser realizado exatamente nas condições que ocorrem no campo, seja sob condições de irrigação ou de sequeiro.

Variáveis cujos vetores estão na mesma direção do gráfico ou cujo cosseno do ângulo entre eles é próximo a um apresentam forte correlação positiva (Figura 3). Assim, as variáveis de trocas gasosas (A , g_s , E) e índices vegetativos (NDVI, GNDVI, GRVI, DVI, NDRE, SAVI, PRI, OSAVI, TCRI), por exemplo, estão correlacionadas positivamente. A mesma interpretação pode ser feita para as variáveis EUA, iEUA e razão raiz/parte aérea (RA.PA). Em contraste, as variáveis WUE e assimilação líquida de CO_2 (A) apresentam correlação negativa (Figuras 3 e 4). Existem correlações entre índices vegetativos e índices de trocas gasosas, pois formaram ângulos agudos entre essas variáveis, mostrando uma correlação positiva com a produtividade de grãos, que deve ser o principal critério para a seleção, pois a produtividade tem maior interesse.

Com exceção do TCARI/OSAVI (TO), os demais índices vegetativos têm uma forte correlação positiva ($>0,6$, $p<0,05$) com o rendimento de grãos, taxa fotossintética, condutância estomática e transpiração (Figura 4). Esses IVs apresentaram correlações entre 0,2 e 0,6 com clorofila a e b, massa da parte aérea e massa de mil grãos e correlações entre 0,05 e 0,19 com massa de raiz. Correlações negativas acima de 0,5 ocorrem entre índices vegetativos com EUA, iEUA, TO e razão clorofila a para clorofila b. Correlações positivas são observadas entre as variáveis EUA e iEUA (0,46, $p<0,05$) (Figura 4). Isso mostra que a eficiência no uso de água está ligada não somente ao desperdício de água nos maiores níveis de irrigação, mas também a capacidade das plantas de utilizar eficientemente devido a mecanismos fisiológicos/foliare.

Os resultados obtidos neste trabalho mostraram que as variáveis fisiológicas A e g_s apresentaram alta correlação com a produtividade (0,68 e 0,76 respectivamente), mas a determinação das trocas gasosas possuem a limitação de não serem viáveis em larga escala, enquanto que os índices vegetativos TCARE, NDVI, OSAVI, SAVI, PRI, NDRE e GNDVI, foram os que apresentaram maior correlação com a produtividade ($>0,7$, $p<0,05$) e possuem a vantagem de serem determinados em maior escala e podem ser uma ferramenta útil em

programas de melhoramento de plantas (Figura 4). Os índices de vegetação foram, em geral, correlacionados entre si, podendo causar redundância e, por isso, um deles pode ser utilizado para o processo de seleção de genótipos de trigo.

As determinações não destrutivas simples e rápidas, como o PRI e NDRE constituem uma vantagem importante sobre as avaliações fisiológicas e poderão ser utilizadas na detecção de plantas sob estresse hídrico, especialmente para a detecção de nível severo ou estágio tardio de estresse de calor e hídrico (CAO et al., 2019). Correlações positivas dos índices de vegetação NDVI, GNDVI, TCARI, OSAVI e correlações negativas entre o índice TCARI/OSAVI com biomassa e rendimento de grãos na cultura do trigo foram relatadas por Frels et al. (2018).

Variáveis relacionadas a índices vegetativos, trocas gasosas, teores de clorofila, MMG, RG, EUA e iEUA foram as mais importantes para diferenciar grupos de genótipos e níveis de regime hídrico (Figura 3), pois possuem pesos (comprimento das setas no gráfico *biplot* ($\cong 1,0$)) maiores, e isso demonstra que essas variáveis são mais indicativas do desempenho dos genótipos sob estresse hídrico e também são variáveis importantes no processo de seleção de genótipos mais produtivos. A massa radicular (0-20 cm) apresentou baixo peso (0,25) para diferenciar regimes hídricos e grupos de genótipos.

Sob irrigação plena, os grupos de genótipos no RH4 (100% da reposição da ETc) apresentaram maiores índices vegetativos e atividade fotossintética, promovendo maiores rendimentos de grãos (Figura 3). Genótipos sob condições de estresse (RH1: 22% da reposição da ETc) apresentam maiores valores de EUA, iEUA, relação à massa de raiz/parte aérea e TO (TCARI/OSAVI) (Tabelas 1 e 2), possivelmente devido ao menor desperdício de água, e TO, por exemplo, é um preditor espectral de concentrações de pigmento do dossel que é sensível à variação de clorofila (BALLESTER et al., 2018). Como iEUA envolve dados de trocas gasosas no cálculo, não apenas desperdício de água que percola no solo, mas também eficiência foliar pode estar envolvida no mecanismo de tolerância ao stress hídrico.

De acordo com Liu et al. (2018) as raízes contribuem com apenas 10 a 20% do peso total da planta, mas um sistema radicular bem desenvolvido é essencial para a absorção de nutrientes e água e, portanto, para o crescimento e produtividade das culturas. Plantas sob condições de disponibilidade limitada de água durante o crescimento vegetativo, aumentam o volume das raízes para aumentar a absorção de água e nutrientes (LINCH, 2018) e evitar as perdas de rendimento.

Os grupos de genótipos apresentaram respostas lineares positivas para a variável latente (coordenada principal 1) (Figura 5A) em função do regime hídrico. O grupo 3 apresentou uma resposta ($b = 0,0326$) 18% maior em média, quando comparado aos outros dois grupos, o que provavelmente ocorreu porque os genótipos do grupo 3 são classificados como biótipos irrigados, exceto os biótipos PF 100368 e TBIO Sintonia. As alterações na disponibilidade hídrica promoveram mudanças significativas em todas as características de acordo com os pesos (comprimento da seta horizontal no *biplot*) na coordenada principal 1 (Figura 3).

Os dados obtidos por outros autores também relatam que sob déficit hídrico, as relações hídricas e o metabolismo das plantas são prejudicados (OUYANG et al., 2017; MARČEK et al., 2019). A fotossíntese pode ser afetada pela atividade da Rubisco e limitada pela concentração de CO_2 do cloroplasto, ou seja, em condições de déficit hídrico, as plantas fecham os estômatos para evitar a transpiração, o que reduz a fotossíntese ao diminuir o influxo de CO_2 (AHMED et al., 2020).

Além da limitação direta, o estresse hídrico pode causar alterações morfológicas nas plantas, como alterações na organização dos cloroplastos e no número de pigmentos, principalmente clorofilas e xantofilas, que consomem energia e levam a menores rendimentos de grãos (LIU et al., 2016; AHMED et al., 2019), além de reduzir o número e o comprimento das espiguetas em trigo (SOARES et al., 2021). Em geral, o ácido abscísico (ABA) regula e

estimula o fechamento estomático e a manutenção do balanço hídrico e estimula a transcrição e a atividade de enzimas antioxidantes em condições de déficit hídrico (WANG et al., 2021).

Li et al. (2021) descrevem que entre as estratégias de escape ou tolerância ao estresse hídrico, os genótipos de trigo reduzem a área foliar, teor de clorofila, número de perfilhos, altura da planta e a condutância estomática para evitar a perda de água; aumentam o comprimento radicular e a razão raiz/parte aérea, provavelmente para aumentar a capacidade de absorção de água; aumentam o teor de prolina nas folhas e a planta reduz o ciclo.

Outros estudos mostram que o estresse hídrico altera a morfologia do sistema radicular de plantas de trigo. Por exemplo, podem ocorrer mudanças no ângulo da raiz, comprimento da raiz primária, número de raízes laterais (ZHAN e LYNCH 2015), diâmetro médio da raiz (HALING et al., 2013) e massa da raiz (KHADKA et al., 2020).

No presente estudo, no RH1 (reposição de 22% ETc), foi observada uma redução de 31% na massa da parte aérea em relação ao regime hídrico não estressado (RH4 - reposição de 100% ETc) (Tabela 2) e uma redução na razão de massa da parte aérea e massa de raiz, sugerindo que plantas de trigo aumentam o sistema radicular como estratégia para absorver mais água. Chen et al. (2017) relataram que em condições de deficiência hídrica, o trigo desenvolve sementes e raízes nodais com ângulo mais estreito, que tendem a crescer mais profundamente do que aquelas com maior ângulo de raiz, e a aumentar a densidade radicular e diminuir o diâmetro, podendo atingir camadas mais profundas de solo.

As variáveis rendimento de grãos, assimilação líquida de CO₂, eficiência no uso da água e NDVI foram as mais afetadas pelo regime hídrico (Figura 3), o que pode torná-las mais eficientes no processo de seleção de genótipos. Os grupos de genótipos apresentaram respostas exponenciais para rendimento de grãos (Figura 5B) e assimilação líquida de CO₂ (Figura 5C), e uma resposta logarítmica para NDVI (Figura 5D), eficiência agrônômica no uso da água (Figura 5E) e eficiência no uso de água intrínseca (Figura 5F) em função dos regimes hídricos.

O aumento da disponibilidade hídrica aumentou o NDVI e a atividade fotossintética, promovendo maior produtividade de grãos. Os genótipos dos grupos 2 e 3 responderam mais rapidamente à disponibilidade hídrica do que os genótipos do grupo 1 para as variáveis produtividade de grãos, assimilação líquida de CO₂ e NDVI.

Houve maior eficiência no uso da água, agronômica e intrínseca (EUA e iEUA, respectivamente), em condições de menor disponibilidade hídrica e os valores dessa eficiência são reduzidos mais rapidamente nos genótipos do grupo 3 e 2 do que nos genótipos do grupo 1.

Soares et al. (2021) também obtiveram diferenças entre genótipos de trigo para tolerância à seca, sendo que, as variáveis número de espigas, massa de mil grãos, rendimento de grãos e peso hectolitro foram características importantes para a seleção de genótipos mais produtivos, e as variáveis DRI e eficiência no uso da água foram importantes para classificar os genótipos quanto à tolerância à seca.

A eficiência no uso da água é uma variável relacionada à capacidade de uma planta produzir grãos com menor quantidade de água. A eficiência do uso da água pelas plantas de trigo aumentou sob estresse hídrico moderado e diminuiu sob irrigação plena (LIU et al., 2016; ZHAO et al., 2020). O uso de genótipos com maior eficiência no uso da água (YASI et al., 2020), principalmente para espécies com alta demanda hídrica sob sequeiro (TAVERA et al., 2018) reduz as perdas de culturas em áreas com escassez de água.

3.4. Conclusões

Os genótipos de trigo apresentaram diferentes respostas ao estresse hídrico e podem ser agrupados.

Índices vegetativos de alto rendimento e não destrutivos baseados na faixa do infravermelho próximo podem ser usados para detectar a tolerância à seca de genótipos de trigo,

pois são responsivos ao estresse hídrico e correlacionados com características fisiológicas e agronômicas.

Os genótipos com maior índice de resistência à seca são: Aliança; BR 254; BR 404; CPAC 01019; PF 020062; PF 080492. Os genótipos BRS 264; BR 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; e TBIO Sintonia são os mais afetados pela disponibilidade hídrica.

Há menor variabilidade nas respostas fisiológicas, agronômicas e espectrais dos genótipos de trigo quando cultivados com regime hídrico referente a 100% da reposição da evapotranspiração da cultura.

3.5. Referências

AHMED, H. G. M-D.; SAJJAD, M.; LI, M.; AZMAT, M. A.; RIZWAN, M.; MAQSOOD, R. H.; KHAN, S. H. Selection Criteria for Drought-Tolerant Bread Wheat Genotypes at Seedling Stage. **Sustainability**, v. 11, n. 9, p. 1-17, 2019. DOI: 10.3390/su11092584.

AHMED, H. G. M-D.; ZENG, Y.; YANG, X.; ANWAAR, H. A.; MANSHA, M. Z.; HANIF, C. M. S.; IKRAM, K.; ULLAH, A.; ALGHANEM, S. M. S. Conferring drought-tolerant wheat genotypes through morpho-physiological and chlorophyll indices at seedling stage. **Saudi Journal of Biological Sciences**, v. 27, n. 8, p. 2116-2123, 2020. DOI: 10.1016/j.sjbs.2020.06.019

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. FAO Irrigation and Drainage Paper, 56, Rome, p. 300, 1998.

ANDEREGG, J.; YU K.; AASEN, H.; WALTER, A.; LIEBISCH, F.; HUND, A. Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm. **Frontiers in Plant Science**, v.10, 2020. DOI: 10.3389/fpls.2019.01749

ANWAAR, H. A.; PERVEEN, R.; MANSHA, M. Z.; ABID, M.; SARWAR, M.; AATIF, H. M.; UMAR, U. U. D.; SAJID, M.; ASLAM, H. M. U.; ALAM, M. M.; RIZWAN, M.; IKRAM,

R. M.; ALGHANEM, S. M. S.; RASHID, A.; KHAN, K. A. Assessment of grain yield indices in response to drought stress in wheat (*Triticum aestivum* L.). **Saudi Journal of Biological Sciences**, v. 27, n. 7, p. 1818-1823, 2020. DOI: <https://doi.org/10.1016/j.sjbs.2019.12.009>

BALLESTER, C.; ZARCO-TEJADA, P. J.; NICOLÁS, E.; ALARCÓN, J. J.; FERERES, E.; INTRIGLIOLO, D. S.; GONZALEZ-DUGO, V. Evaluating the performance of xanthophyll, chlorophyll and structure-sensitive spectral indices to detect water stress in five fruit tree species. **Precision Agriculture**, 19, 178–193, 2018. DOI: <https://doi.org/10.1007/s11119-017-9512-y>

BOWMAN, B.; CHEN, J.; ZHANG, J.; WHEELER, J.; WANG, Y.; ZHAO, W.; NAYAK, S.; HESLOT, N.; BOCKELMAN, H.; BONMAN, J. Evaluating Grain Yield in Spring Wheat with Canopy Spectral Reflectance. **Crop Science**, v. 55, n. 5, p. 1881–1890, 2015. DOI: <https://doi.org/10.2135/cropsci2014.08.0533>

BOX, G. E. P. A general distribution theory for a class of likelihood criteria. **Biometrika**, 36, 317-346, 1949. DOI: <https://doi.org/10.2307/2332671>.

CAO, Z.; YAO, X.; LIU, H.; LIU, B.; CHENG, T.; TIAN, Y.; CAO, W.; ZHU, Y. Comparison of the abilities of vegetation indices and photosynthetic parameters to detect heat stress in wheat. **Agricultural and Forest Meteorology**, 265, 121-136, 2019. DOI: <https://doi.org/10.1016/j.agrformet.2018.11.009>.

CATTELAN, A. J.; DALL'AGNOL, A. The rapid soybean growth in Brazil. **Oilseeds & fats Crops and Lipids**, v.25, p.1-12, 2018. DOI: doi.org/10.1051/ocl/2017058.

CHEN, X.; DING, Q.; BŁASZKIEWICZ, Z.; SUN, J.; SUN, Q.; HE, R.; LI, Y. Phenotyping for the dynamics of field wheat root system architecture. **Scientific Reports**, v. 7, n. 37649, 2017. DOI: [10.1038/srep37649](https://doi.org/10.1038/srep37649)

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, p. 229-239, 2000. DOI: [doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)

EMBRAPA. Programa De Monitoramento Da Irrigação. EMBRAPA, Brasília, 2011.

FRELS, K.; GUTTIERI, M.; JOYCE, B.; LEAVITT, B.; BAENZIGER, P. S. Evaluating canopy spectral reflectance vegetation indices to estimate nitrogen use traits in hard winter wheat. **Field Crops Research**, 217, 82-92, 2018. DOI: <https://doi.org/10.1016/j.fcr.2017.12.004>.

FISCHER, R. A; MAURER, R. Drought resistance in spring wheat cultivars. I. Grain yield responses. **Australian Journal of Agricultural Research**, v. 29, n. 5, p. 897-912, 1978. DOI: <https://doi.org/10.1071/AR9780897>

GABRIEL, K. R. The biplot graphical display of matrices with application to principal component analysis. **Biometrika**, 58, 453-467, 1971. DOI: <https://doi.org/10.2307/2334381>.

GAMON, J. A.; PENUELAS, J.; FIELD, C. B. A. Narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, n. 1, p. 35-44, 1992. DOI: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)

GENTY, B.; BRIANTAIS, J. M.; BAKER, N. R. The relationship between the quantum yield of photosynthetic electron transport and quenching of chlorophyll fluorescence. **Biochimica et Biophysica Acta**, 990, 87-92, 1989. DOI: [https://doi.org/10.1016/S0304-4165\(89\)80016-9](https://doi.org/10.1016/S0304-4165(89)80016-9).

GITELSON, A.; MERZLYAK, M.N. Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology**, v. 22, n.3, p. 247-252, 1994. DOI: [https://doi.org/10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrowband vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, p. 416-426, 2002. DOI: [doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4).

HALING, R. E.; BROWN, L. K.; BENGOUGH, A. G.; YOUNG, I. M.; HALLETT, P. D.; WHITE, P. J. Root hairs improve root penetration, root – soil contact, and phosphorus acquisition in soils of different strength. **Journal of Experimental Botany**, v. 64, n. 12, p. 3711–3721, 2013. DOI: [10.1093/jxb/ert200](https://doi.org/10.1093/jxb/ert200)

HANKS, R. J.; KELLER, J.; RASMUSSE, V. P.; WILSON, G. D. Line source sprinkler for continuous variable irrigation crop production studies. **Soil Science Society of America Journal**, v. 40, n. 3 p. 426–429, 1976. DOI: 10.2136/sssaj1976.03615995004000030033x

HATFIELD, J. L.; SAUER, T. J.; PRUEGER, J. H. Managing soils to achieve greater water use efficiency: a review. **Agronomy Journal**, v.93, p.271-280, 2001. DOI: 10.2134/agronj2001.932271x

HIJMANS, R. J. **Raster**: Geographic data analysis and modeling. R package version 2.2-31. [on-line3], 2014. <http://CRAN.Rproject.org/package=raster>

HU, Y.; KNAPP, S.; SCHMIDHALTER, U. Advancing High-Throughput Phenotyping of Wheat in Early Selection Cycles. **Remote Sensing**, v.12, n.3, 574, 2020. DOI: <https://doi.org/10.3390/rs12030574>

JAYME-OLIVEIRA, A.; RIBEIRO JUNIOR, W. Q.; RAMOS, M. L. G.; ZIVIANI, A. C.; JAKELAITIS, A. Amaranth, quinoa, and millet growth and development under different water regimes in the Brazilian Cerrado. **Pesquisa Agropecuária Brasileira**, v. 52, n. 8, 561–571, 2017. <https://doi.org/10.1590/s0100-204x2017000800001>

KHADKA, K.; EARL, H. J.; RAIZADA, M. N.; NAVABI, A. A Physio-Morphological Trait-Based Approach for Breeding Drought Tolerant Wheat. **Frontiers in Plant Science**, v. 11, 2020. DOI: 10.3389/fpls.2020.00715

LI, P.; MA, B.; PALTA, J. A.; DING, T.; CHENG, Z.; LV, G.; XIONG, X. Wheat breeding highlights drought tolerance while ignores the advantages of drought avoidance: A meta-analysis. **European Journal of Agronomy**, v. 122, 126196, 2021. DOI: <https://doi.org/10.1016/j.eja.2020.126196>

LIU, E. K.; MEI, X. R.; YAN, C. R.; GONG, D. Z.; ZHANG, Y. O. Effects of water stress on photosynthetic characteristics, dry matter translocation and WUE in two winter wheat genotypes. **Agricultural Water Management**, v. 167, n.3, p. 75-85, 2016. DOI: <https://doi.org/10.1016/j.agwat.2015.12.026>

LIU, W.; WANG, J.; WANG, C.; MA, G.; WEI, Q.; LU, H.; XIE, Y.; MA, D.; KANG, G. Root Growth, Water and Nitrogen Use Efficiencies in Winter Wheat Under Different Irrigation and Nitrogen Regimes in North China Plain. **Frontiers Plant Science**, 9, 2018. DOI: <https://doi.org/10.3389/fpls.2018.01798>

LYNCH, J. P. Rightsizing root phenotypes for drought resistance. **Journal of Experimental Botany**, v. 69, n. 13, p. 3279-3292, 2018. DOI: <https://doi.org/10.1093/jxb/ery048>

MARČEK, T.; HAMOW, K.; VÉGH, B.; JANDA, T.; DARKO, E. Metabolic response to drought in six winter wheat genotypes. **PLoS ONE**, v.14, n. 2, p. 1-23, 2019. DOI: <https://doi.org/10.1371/journal.pone.0212411>

MEENA, R. P.; VENKATESH, K.; SENDHIL, R.; KHOBA, R.; SHARMA, R. K.; TRIPATHI, S. C.; SINGH, G. P. Identification of water use efficient wheat genotypes with high yield for regions of depleting water resources in India. **Agricultural Water Management**, v. 223, 105709, 2019. DOI: <https://doi.org/10.1016/j.agwat.2019.105709>.

MICASENSE. How do professional multispectral cameras differ from single-imager multispectral câmeras - RedEdge-MX 2020. Disponível em: <<http://www.micasense.com/>>. Acesso em: 25.fev.2020.

MOJENA, R. Hierarchical grouping methods and stopping rules: an evaluation. **The Computer Journal**, v. 20, n.4, p. 359-363, 1977. DOI: <https://doi.org/10.1093/comjnl/20.4.359>

OUYANG, W.; STRUIK, P. C.; YIN, X.; YANG, J. Stomatal conductance, mesophyll conductance, and transpiration efficiency in relation to leaf anatomy in rice and wheat genotypes under drought, **Journal of Experimental Botany**, v. 68, n. 18, p. 5191–5205, 2017. DOI: <https://doi.org/10.1093/jxb/erx314>

PEREIRA, J. F.; CUNHA, G. R.; MORESCO, E. R. Improved drought tolerance in wheat is required to unlock the production potential of the Brazilian Cerrado. **Crop Breeding and Applied Biotechnology**, v. 19, n.2, p. 217-225, 2019. DOI: <https://doi.org/10.1590/1984-70332019v19n2r30>

PREY, L.; SCHMIDHALTER, U. Simulation of satellite reflectance data using high-frequency ground based hyperspectral canopy measurements for in-season estimation of grain yield and grain nitrogen status in winter wheat. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 149, p. 176–187, 2019. DOI: <https://doi.org/10.1016/j.isprsjprs.2019.01.023>

QIU, R. C.; WEI, S.; ZHANG, M.; SUN, H.; LI, H.; LIU, G.; LI, M. Sensors for measuring plant phenotyping: A review. **International Journal of Agricultural and Biological Engineering**, v. 11, n. 2, p. 1–17, 2018. DOI: [10.25165/j.ijabe.20181102.2696](https://doi.org/10.25165/j.ijabe.20181102.2696)

R CORE TEAM (2017). **R**: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>. [accessed on 15 January 2020]

RATKE, R. F.; PEREIRA, H. S.; SANTOS JR., J. D. G.; FRAZÃO, J. J.; BARBOSA, J. M.; DIAS, B. O. Root Growth, Nutrition and Yield of Maize with Applied Different Limestone Particle Size in the Cerrado Soil. **American Journal of Plant Sciences**, v. 5, n. 4, p. 463-472, 2014. DOI: 10.4236/ajps.2014.54060

RIGON, J. P. G.; CAPUANI, S.; BELTRÃO, N. M.; BRITO NETO, J. F.; SOFIATTI, V.; FRANÇA, V. F. Non-destructive determination of photosynthetic pigments in the leaves of castor oil plants. **Acta Scientiarum Agronomy**, v. 34, n. 3, p. 325-329, 2012. DOI: 10.4025/actasciagron.v34i3.13872

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95-107, 1996. DOI: 10.1016/0034-4257(95)00186-7

ROUSE, J. W.; JR. HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **Proc 3rd ERTS Symp 1**, p. 48-62, 1973.

SANTOS, H. G.; JACOMINE, P. K. T.; DOS ANJOS, L. H. C.; DE OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; DE ALMEIDA, J. A.; ARAÚJO FILHO, J. C. de; OLIVEIRA, J. B. de; CUNHA, T. J. F. Sistema brasileiro de classificação de solos. Brasília, DF: Embrapa, 2018.

SILVA, A. N.; RAMOS, M. L. G.; RIBEIRO JUNIOR, W. Q.; ALENCAR, E. R.; SILVA, P. C.; LIMA, C. A.; VINSON, C. C.; SILVA, M. A. V. Water stress alters physical and Chemical quality ingrains of common bean, triticale and wheat. **Agricultural Water Management.**, 231, 16023, 2020. DOI: <https://doi.org/10.1016/j.agwat.2020.106023>

SINGH, D. The relative importance of characters affecting genetic divergence. **Indian Journal Genetics & Plant Breeding**, v.41, n. 2, p. 237-245, 1981.

SOARES, G. F.; RIBEIRO JÚNIOR, W. Q.; PEREIRA, L. F.; LIMA, C. A.; SOARES, D. S.; MULLER, O.; RASCHER, U.; RAMOS, M. L. G. Characterization of wheat genotypes for drought tolerance and water use efficiency. **Scientia Agricola**, v. 78, n. 5, e20190304, 2021. DOI: <https://doi.org/10.1590/1678-992x-2019-0304>

SRIPADA, R. P.; HEINIGER, R.W.; WHITE, J. G.; MEIJER, A. D. Aerial Color Infrared Photography for Determining Early In-season Nitrogen Requirements in Corn. **Agronomy Journal**, v. 98, p. 968-977, 2006. DOI: <https://doi.org/10.2134/agronj2005.0200>

STEVEN, M. D. The sensitivity of the OSAVI vegetation index to Observational Parameters. **Remote Sensing of Environment**, v. 63, p. 49, 1998. DOI: [10.1016/S0034-4257\(97\)00114-4](https://doi.org/10.1016/S0034-4257(97)00114-4)

TAVERA, V. C.; MANCILLA, C. L. A.; GALLEGOS, J. A. C.; PIMENTEL, J. G. R.; ARRIAGA, A. I. M.; RUIZ NIETTO, J. E. Mechanisms for water use efficiency between bean cultivars tolerant to drought are different. **Acta Scientiarum Agronomy**, v. 40, 2018. DOI: <https://doi.org/10.4025/actasciagron.v40i1.39378>

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

VAN GENUCHTEN, M.T. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, v.44, p.892-898, 1980. DOI: <https://doi.org/10.2136/sssaj1980.03615995004400050002x>

WANG, L.; WANG, S.; CHEN, W.; LI, H.; DENG, X. Physiological mechanisms contributing to increased water-use efficiency in winter wheat under organic fertilization. **PLoS ONE**, v. 12, n. 6, e0180205, p. 1-21, 2017. DOI: <https://doi.org/10.1371/journal.pone.0180205>.

WANG, X.; LI, Q.; XIE, J.; HUANG, M.; CAI, J.; ZHOU, Q.; DAI, T.; JIANG, D. Abscisic acid and jasmonic acid are involved in drought priming-induced tolerance to drought in wheat. **The Crop Journal**, v. 9, n. 1, p. 120-132, 2021. DOI: <https://doi.org/10.1016/j.cj.2020.06.002>.

YANG, M.; HASSAN, M. A.; XU, K.; ZHENG, C.; RASHEED, A.; ZHANG, Y.; JIN, X.; XIA, X.; XIAO, Y.; HE, Z. Assessment of Water and Nitrogen Use Efficiencies Through UAV-Based Multispectral Phenotyping in Winter Wheat. **Frontiers in Plant Science**, v. 11, 2020. DOI: [10.3389/fpls.2020.00927](https://doi.org/10.3389/fpls.2020.00927)

YASI, H; ATTIA, H; ALAMER, K; HASSAN, F; ALI, E; ELSHAZLY, S; SIDDIQUE, K.H.M; HESSINI, K. Impact of drought on growth, photosynthesis, osmotic adjustment, and cell wall elasticity in Damask rose. **Plant Physiology and Biochemistry**, v. 150, p. 133-139, 2020. DOI: <https://doi.org/10.1016/j.plaphy.2020.02.038>

ZHAN, A.; LYNCH, J. P. Reduced frequency of lateral root branching improves N capture from low-N soils in maize. **Journal of Experimental Botany**, v. 66, n. 7, p. 2055–2065, 2015. DOI: 10.1093/jxb/erv007

ZHAO, W.; LIU, L.; SHEN, Q.; YANG, J.; HAN, X.; TIAN, F.; WU, J. Effects of Water Stress on Photosynthesis, Yield, and Water Use Efficiency in Winter Wheat. **Water**, v. 12, n. 8, p. 1-19, 2020. DOI: <https://doi.org/10.3390/w12082127>

ZÖRB, C.; LUDEWIG, U.; HAWKESFORD, M. J. Perspective on Wheat Yield and Quality with Reduced Nitrogen Supply. **Trends in Plant Science**, v. 23, n. 11, p. 1029-1037, 2018. DOI: <https://doi.org/10.1016/j.tplants.2018.08.012>

3.6 Apêndice

Tabela 1. Valores médios dos índices vegetativos e produtividade do trigo em função dos grupos de genótipos e regimes hídricos nas safras 2018 e 2019.

G ^{1/}	RH	Variáveis												
		NDVI	SAVI	PRI	DVI	GRVI	GNDVI	NDRE	TCARI	OSAVI	TO	UG	MMG	RG
1	22	0.27	0.18	0.1	1.81	3.09	0.5	0.12	0.12	0.22	0.54	10.5	32.97	2337
	43	0.45	0.28	0.16	3.17	3.89	0.58	0.25	0.14	0.36	0.4	10.8	35.19	3691
	81	0.62	0.38	0.21	5.58	4.7	0.63	0.34	0.18	0.49	0.38	11.3	37.56	5076
	100	0.65	0.39	0.22	6.27	5.06	0.65	0.35	0.18	0.51	0.37	11.4	38.74	5604
2	22	0.29	0.19	0.12	1.93	3.15	0.51	0.14	0.12	0.24	0.54	11.2	33.68	1983
	43	0.47	0.3	0.17	3.38	3.97	0.58	0.26	0.15	0.38	0.41	10.9	36.2	3913
	81	0.63	0.39	0.23	5.91	4.82	0.63	0.35	0.18	0.5	0.37	11.6	36.99	5095
	100	0.65	0.41	0.23	6.6	5.2	0.66	0.37	0.18	0.52	0.36	11.8	38.43	5439
3	22	0.24	0.16	0.09	1.67	2.93	0.49	0.11	0.11	0.2	0.55	10.3	32.43	2366
	43	0.4	0.24	0.14	2.56	3.51	0.55	0.21	0.13	0.31	0.43	10.3	36.31	4013
	81	0.6	0.37	0.21	5.04	4.38	0.61	0.31	0.19	0.47	0.4	10.6	39.97	5653
	100	0.64	0.39	0.22	6.04	4.86	0.64	0.33	0.19	0.51	0.39	10.8	40.43	6052
	Média	0.49	0.31	0.17	4.16	4.13	0.59	0.26	0.16	0.39	0.43	10.9	36.57	4269
	EP	0.05	0.03	0.01	0.55	0.24	0.02	0.03	0.01	0.04	0.02	0.15	0.76	414.5
	CV	3.28	3.1	2.97	4.62	1.98	1.03	3.67	2.02	3.19	1.66	0.46	0.72	3.36

^{1/} G: grupos de genótipos; RH: regimes hídricos (22, 43, 81 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente); NDVI: Normalized Difference Vegetation Index; SAVI: Soil Adjusted Vegetation Index; PRI: Photochemical Physiological Reflectance Index; DVI: Difference Vegetation Index; GRVI: Green-Red Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; NDRE: Normalized Difference Red Edge; TCARI: Chlorophyll Absorption and Reflectance Index; OSAVI: Optimized Soil Adjusted Vegetation Index; TO: TCARI/OSAVI; UG: humidade do grão (%); MMG: massa de mil grãos (g); RG: rendimento de grãos (Kg ha⁻¹); DRI: Drought Resistance Index; Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia. EP: erro padrão; CV: coeficiente de variação (%).

Tabela 2. Valores médios para as variáveis morfofisiológicas e índice de tolerância à seca do trigo em função dos grupos de genótipos e regimes hídricos nas safras 2018 e 2019.

G ^{1/}	RH	Variáveis													
		EUA	Cha	Chb	RA	PA	A	g _s	iEUA	Ci	E	Fv'/Fm'	ETR	Fv/Fm	DRI
1	22	22.7	30.9	7.2	4.9	10.4	8.7	0.09	121.9	188	2.5	0.46	122	0.8	1.01
	43	19.5	35.5	10.5	5	12.2	15.8	0.13	96.8	204	3.2	0.5	144	0.82	
	81	14.3	39.4	14.1	5.8	15.7	22.3	0.33	67.8	248	6.3	0.57	148	0.82	
	100	12.5	41.0	16.0	5.7	15.6	22.7	0.48	47.2	275	8.7	0.59	151	0.83	
2	22	20.3	32.0	8.2	5.4	11.1	9.7	0.09	125.6	193	2.5	0.47	133	0.81	0.95
	43	19.1	35.3	11.4	9.8	12.9	15.1	0.12	108.4	175	3.2	0.51	146	0.83	
	81	14.1	40.2	16.1	6.1	13.6	21.6	0.39	55.5	263	7.8	0.6	150	0.83	
	100	12.2	41.6	16.7	5.6	15.2	22.1	0.53	41.8	273	9.9	0.6	164	0.83	
3	22	22.0	27.4	5.4	4.8	9.9	8.1	0.09	127.1	168	2.6	0.4	99	0.8	0.93
	43	20.3	32.6	8.2	5.1	11.6	16.0	0.1	112.0	144	2.9	0.5	116	0.81	
	81	16.0	38.6	13	5.2	15.7	23.1	0.41	56.4	259.9	7.68	0.6	159	0.82	
	100	13.6	40.2	14.2	5.5	17.1	23.9	0.61	49.3	294.9	11.55	0.6	142	0.83	
Média		17.2	36.1	11.7	5.7	13.4	17.4	0.28	84.1	224.2	5.75	0.5	140	0.82	0.96
Erro padrão		1.1	1.34	1.1	0.4	0.7	1.7	0.06	4.87	14.56	0.96	0.02	5.49	0.09	0.01
CV		2.2	1.28	3.3	2.3	1.8	3.4	7.05	1.12	2.25	5.77	1.29	1.36	0.13	0.11

^{1/} G: grupos de genótipos; RH: regimes hídricos (22, 43, 81 e 100% ETc - RH1, RH2, RH3 e RH4, respectivamente); EUA: eficiência no uso da água; Cha: clorofila a; Chb: clorofila b; RA: massa de raiz; PA: massa parte aérea; A: assimilação líquida de CO₂ (μmol CO₂ m⁻² s⁻¹); g_s: condutância estomática (mol H₂O m⁻² s⁻¹); eficiência intrínseca no uso da água (iEUA - A/g_s); Ci: concentração interna CO₂; E: transpiração (mmol H₂O m⁻² s⁻¹); Fv'/Fm': eficiência efetiva do fotossistema II; (ETR) cadeia transporte de elétrons; Fv/Fm: rendimento quântico máximo do fotossistema II. Grupo1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia. CV: coeficiente de variação (%).

Tabela 3. Importância relativa (percentagem) de variáveis no distanciamento entre genótipos pelo Critério de Singh (1981).

Variáveis	Percentagem (%)
SAVI	33
OSAVI	33
DVI	11
NDRE	11
GNDVI	3
NDGI	2
RVI	2
NDVI	1
GRVI	1
RG	1
Outras	< 2

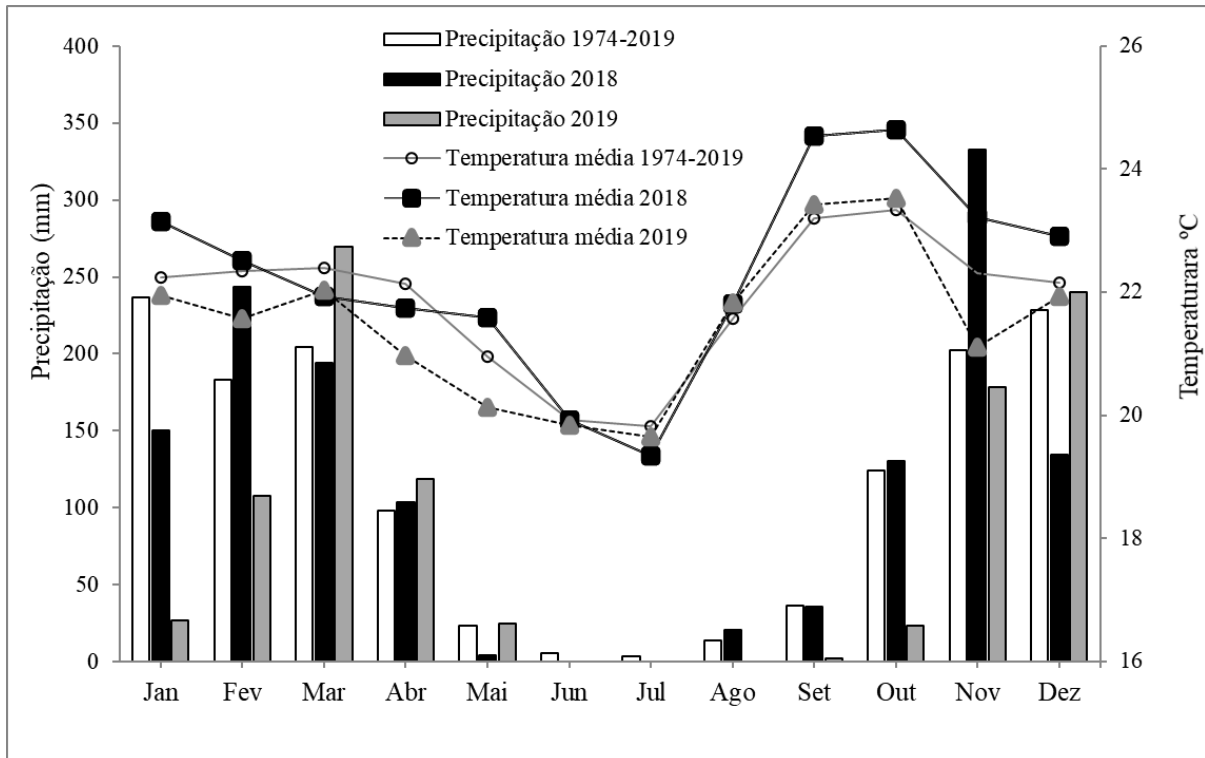


Figura 1. Precipitação e temperatura média obtidos em uma estação meteorológica automatizada localizada ao lado do experimento, nos anos de 2018 e 2019 e uma série histórica (1974-2019).




Figura 2. Dendrograma obtido com o método de Ward com base na distância generalizada de Mahalanobis para agrupamento de 18 genótipos de trigo. Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 368; TBIO Sintonia.




Figura 3. Biplot para médias de regimes hídricos (RH1, RH2, RH3 e RH4 - 22, 43, 81, 100% ETc, respectivamente) e grupos de genótipos de trigo (1, 2, 3) com base nos escores (pesos) das variáveis: Relação RA/PA (RA.PA); Razão Clorofila a/b (Cha.b); Eficiência no uso da água (EUA); Relação TCRI/OSAVI (TO); Eficiência intrínseca do uso da água (iEUA - A/g_s); Taxa de transporte de elétrons (ETR); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Umidade do grão (UG); Clorofila b (Chb); Clorofila a (Cha); Corofila total (Cht); Índice de Resistência à Seca (DRI); Massa de raiz (RA); Concentrações internas de CO₂ (Ci); Massa de mil grãos (MMG); Massa de parte aérea (PA); Rendimento Quântico Efetivo do Fotossistema (Fv'/Fm'); Condutância Estômica (gs); Transpiração (E); Rendimento de grãos (RG); Assimilação Líquida de CO₂ (A); The Transformed Chlorophyll Absorption and Reflectance Index (TCARI); Green red vegetation index (GRVI); Normalized difference vegetation index (NDVI); Optimized Soil Adjusted Vegetation Index (OSAVI); Soil adjusted vegetation index (SAVI); Photochemical Physiological Reflectance Index (PRI); Green normalized difference vegetation index (GNDVI); Red Edge Normalized Difference (NDRE); Difference vegetation index (DVI). Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; Grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; Grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia.




Figura 4. Correlograma de Pearson entre variáveis fisiológicas, espectrais e agrônômicas em função dos regimes hídricos (22, 43, 81 e 100% da reposição ET_c - RH1, RH2, RH3 e RH4, respectivamente) e grupos de genótipos de trigo (1, 2, 3), com base nos escores das coordenadas principais das variáveis: Relação RA/PA (RA.PA); Razão Clorofila a/b (Cha.b); Eficiência no uso da água (EUA); Relação TCRI/OSAVI (TO); Eficiência intrínseca do uso da água (iEUA - A/gS); Taxa de transporte de elétrons (ETR); Rendimento Quântico Máximo do Fotossistema II (Fv/Fm); Umidade do grão (UG); Clorofila b (Chb); Clorofila a (Cha); Corofila total (Cht); Índice de Resistência à Seca (DRI); Massa de raiz (RA); Concentrações internas de CO_2 (Ci); Massa de mil grãos (MMG); Massa de parte aérea (PA); Rendimento Quântico Efetivo do Fotossistema (Fv'/Fm'); Condutância Estômica (gs); Transpiração (E); Rendimento de grãos (RG); Assimilação Líquida de CO_2 (A); The Transformed Chlorophyll Absorption and Reflectance Index (TCARI); Green red vegetation index (GRVI); Normalized difference vegetation index (NDVI); Optimized Soil Adjusted Vegetation Index (OSAVI); Soil adjusted vegetation index (SAVI); Photochemical Physiological Reflectance Index (PRI); Green normalized difference vegetation index (GNDVI); Red Edge Normalized Difference (NDRE); Difference vegetation index (DVI). Grupo 1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; Grupo 2: BR 18_Terena; MGS Brilhante; PF 020037; PF 120337; Grupo 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia.

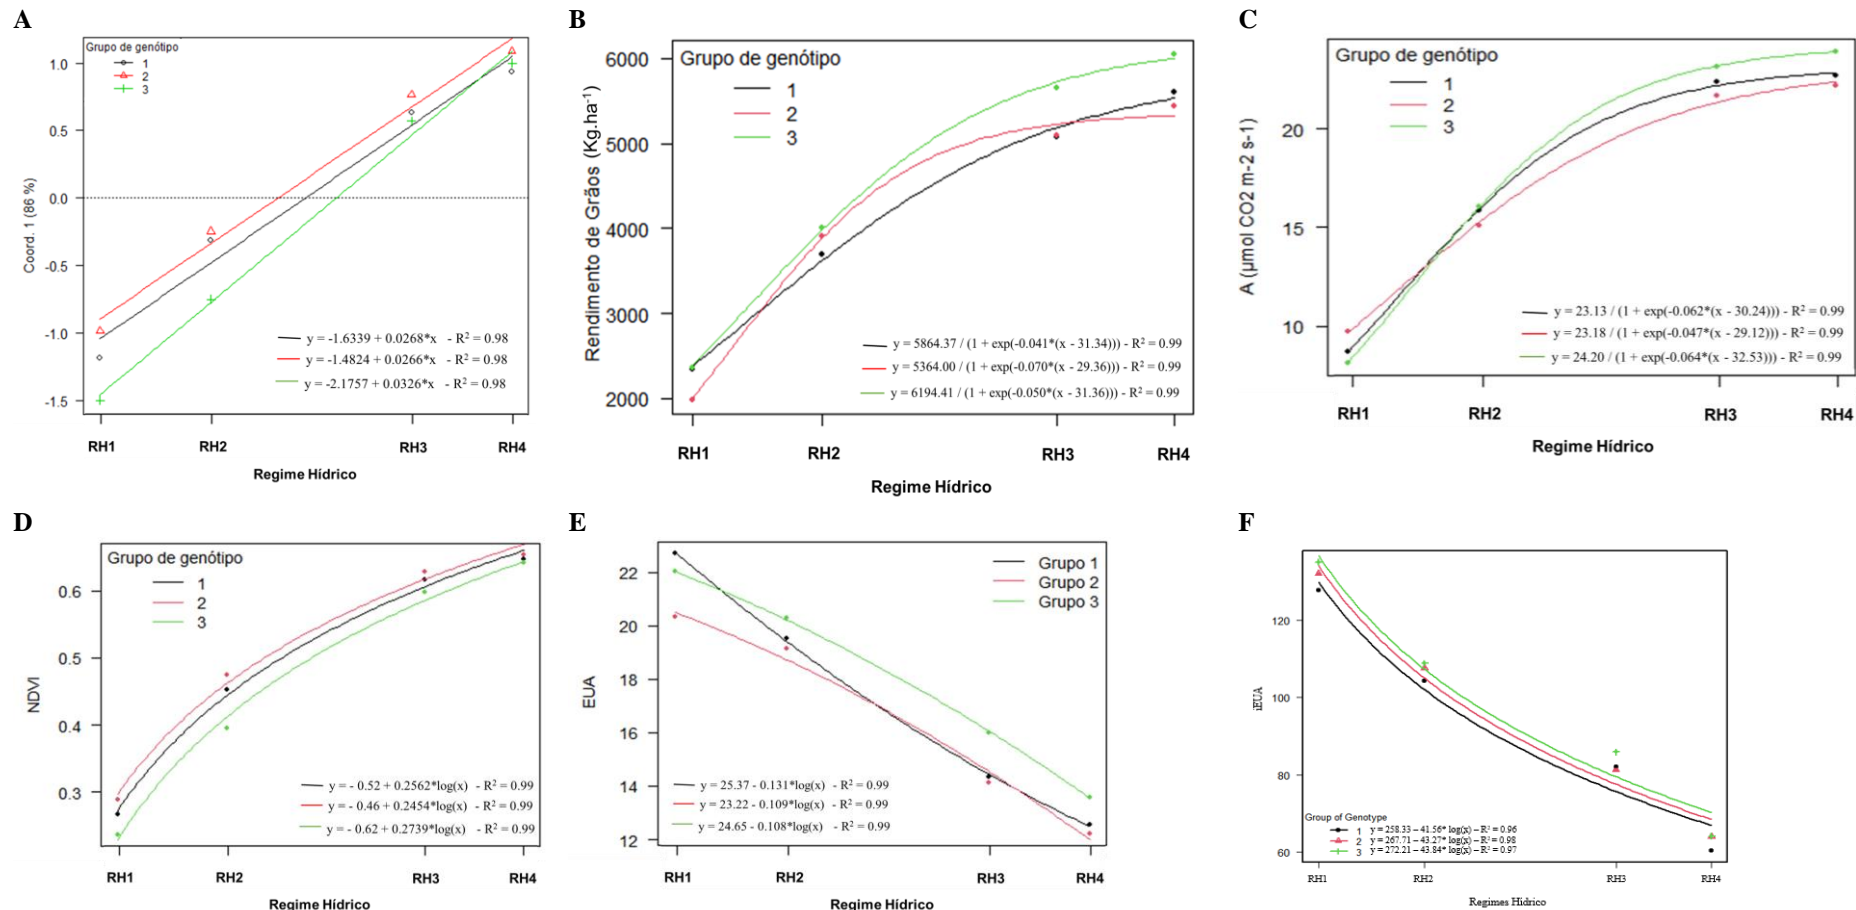


Figura 5. Equações de regressão e os respectivos coeficientes de determinação (R^2) das variáveis: A- Coordenada Principal 1 - variável latente (Coord. 1), B- Rendimento de Grãos, C- Assimilação líquida de CO₂, D- Índice de Vegetação por Diferença Normalizada (NDVI), E- Eficiência no Uso de Água (EUA) e, F- Eficiência intrínseca no Uso de água (iEUA) em função dos regimes hídricos (RH1, RH2, RH3 e RH4 - 22, 43, 81, 100% ETC, respectivamente) e dos grupos de genótipos de trigo (1: Aliança; BRS 254; BRS 404; CPAC 01019; PF 020062; PF 080492; 2: BR 18; MGS Brilhante; PF 020037; PF 120337; 3: BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 368; TBIO Sintonia).

CONSIDERAÇÕES FINAIS

Em ambas as culturas, a condição de estresse hídrico afetou negativamente a morfologia, as trocas gasosas, os índices de vegetação e o rendimento dos grãos, mas em grau diferente nos genótipos estudados.

Os índices espectrais extraídos das imagens capturadas pelos sensores da câmera multiespectral são importantes na divergência dos genótipos e os índices baseados na banda do infravermelho próximo são relacionados com respostas fisiológicas e agrônômicas de trigo e soja. Os índices NDVI, NDRE, TCARI, OSAVI, PRIc são opções para classificação espectral de genótipos de soja em relação a disponibilidade hídrica.

O estresse hídrico promove maior investimento da cultura do trigo em desenvolvimento do sistema radicular, levando a um aumento na relação da massa seca raízes com a parte aérea em condições de déficit hídrico.

Genótipos de trigo com características do grupo III (BRS 264; BRS 394; CPAC 01047; CPAC 07258; CPAC 8318; CPAC 9110; PF 100368; TBIO Sintonia) são mais afetados pela disponibilidade de água.

As cultivares de soja BRS 7280RR e NA 5909RG apresentam melhor desempenho produtivo tanto em maior quanto em menor disponibilidade hídrica, tornando uma opção para o cultivo no Cerrado brasileiro quando há previsão de ocorrência de estresse hídrico.