

**GRUPOS DE MATURAÇÃO DA CULTURA DA SOJA AVALIADOS POR
IMAGENS AÉREAS OBTIDAS POR VANT**

Por

JOÃO CARLOS SILVA FERREIRA

Dissertação apresentada ao Programa de Pós-Graduação em Bioenergia e Grãos do Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Rio Verde, como parte dos requisitos para obtenção do grau de Mestre em Bioenergia e Grãos.

Rio Verde – GO

Outubro de 2020

**GRUPOS DE MATURAÇÃO DA CULTURA DA SOJA AVALIADOS POR
IMAGENS AÉREAS OBTIDAS POR VANT**

JOÃO CARLOS SILVA FERREIRA

Comitê de Orientação:

Orientador: Dr. Pablo Diego Silva Cabral – IF Goiano Campus Rio Verde

Rio Verde – GO

Outubro - 2020

Sistema desenvolvido pelo ICMC/USP
Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas - Instituto Federal Goiano

F383g Ferreira, João Carlos Silva
 GRUPOS DE MATURAÇÃO DA CULTURA DA SOJA AVALIADOS
 POR IMAGENS AÉREAS OBTIDAS POR VANT / João Carlos
 Silva Ferreira; orientador Pablo Diego Silva
 Cabral. -- Rio Verde, 2020.
 50 p.

 Dissertação (Mestrado em Mestrado Profissional em
 Bioenergia e grãos) -- Instituto Federal Goiano,
 Campus Rio Verde, 2020.

 1. Glycine max. 2. Drone. 3. Estádio fenológico.
 I. Silva Cabral, Pablo Diego , orient. II. Título.



TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano, a disponibilizar gratuitamente o documento no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| <input type="checkbox"/> Tese | <input type="checkbox"/> Artigo Científico |
| <input checked="" type="checkbox"/> Dissertação | <input type="checkbox"/> Capítulo de Livro |
| <input type="checkbox"/> Monografia – Especialização | <input type="checkbox"/> Livro |
| <input type="checkbox"/> TCC – Graduação | <input type="checkbox"/> Trabalho Apresentado em Evento |
| <input type="checkbox"/> Produto Técnico e Educacional - Tipo: | _____ |

Nome Completo do Autor: João Carlos Silva Ferreira

Matrícula: 2018202331540064

Título do Trabalho: GRUPOS DE MATUREZAÇÃO DA CULTURA DA SOJA AVALIADOS POR IMAGENS AÉREAS OBTIDAS POR VANT

Restrições de Acesso ao Documento

Documento confidencial: Não Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIIF Goiano: 01/01/2021

O documento está sujeito a registro de patente? Sim Não

O documento pode vir a ser publicado como livro? Sim Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Rio Verde, 14 de dezembro de 2020

Assinatura do Autor e/ou Detentor dos Direitos Autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Documentos 54/2020 - NREPG-RV/CPG-RV/DPGPI-RV/CMPRV/IFGOIANO

GRUPOS DE MATURAÇÃO DE GENÓTIPOS DE SOJA PREDITOS POR IMAGENS AÉREAS OBTIDAS POR VANT

Autor: João Carlos Silva Ferreira
Orientador: Pablo Diego Silva Cabral

TITULAÇÃO: Mestre em Bioenergia e Grãos – Área de concentração Agroenergia.

APROVADO em 30 de outubro de 2020.

Prof.^a Dr.^a Liliam Silvia Candido
Avaliadora externa
Universidade Federal da Grande
Dourados

Prof. Dr. Gustavo Castoldi
Avaliador interno
IF Goiano - Polo de Inovação

Prof. Dr. Pablo Diego Silva Cabral
Presidente da Banca
IF Goiano - Polo de Inovação

Documento assinado eletronicamente por:

- Gustavo Castoldi, PROFESSOR ENS BASICO TECN TECNOLÓGICO, em 05/11/2020 09:14:37.
- Liliam Silvia Candido, Liliam Silvia Candido - Professor Avaliador de Banca - Fundacao Universidade Federal da Grande Dourados - Ufgd [07775847000197], em 04/11/2020 14:13:10.
- Pablo Diego Silva Cabral, PROFESSOR ENS BASICO TECN TECNOLÓGICO, em 30/10/2020 13:00:59.

Este documento foi emitido pelo SUAP em 27/10/2020. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 203542
Código de Autenticação: 23973a61fa





SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Documentos 54/2020 - NREPG-RV/CPG-RV/DPGPI-RV/CMPRV/IFGOIANO

GRUPOS DE MATURAÇÃO DE GENÓTIPOS DE SOJA PREDITOS POR IMAGENS AÉREAS OBTIDAS POR VANT

Autor: João Carlos Silva Ferreira
Orientador: Pablo Diego Silva Cabral

TITULAÇÃO: Mestre em Bioenergia e Grãos - Área de concentração Agroenergia.

APROVADO em 30 de outubro de 2020.

Prof.^a Dr.^a Lilliam Sílvia Candido
Avaliadora externa
Universidade Federal da Grande
Dourados

Prof. Dr. Gustavo Castoldi
Avaliador interno
IF Goiano - Polo de Inovação

Prof. Dr. Pablo Diego Silva Cabral
Presidente da Banca
IF Goiano - Polo de Inovação

Documento assinado eletronicamente por:

- Gustavo Castoldi, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 05/11/2020 09:14:37.
- Lilliam Sílvia Candido, Lilliam Sílvia Candido - Professor Avaliador de Banca - Fundacao Universidade Federal da Grande Dourados - Ufgd [07775847000197], em 04/11/2020 14:13:10.
- Pablo Diego Silva Cabral, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 30/10/2020 13:00:59.

Este documento foi emitido pelo SUAP em 27/10/2020. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 203542
Código de Autenticação: 23973a61fa



DEDICATÓRIA

Dedico primeiramente a Deus, a minha mãe Eliana Aparecida Silva Ferreira, a minha esposa Germanna Gouveia Tavares e a toda minha família.

A GDM Genética do Brasil e também ao Programa de Pós-Graduação em Bioenergia e Grãos.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus e a minha família pelo apoio, em especial a minha esposa Germana Gouveia Tavares, que me auxiliou por toda essa caminhada.

Ao meu Orientador Professor Dr Pablo Diego Silva Cabral pelos ensinamentos, paciência e orientação.

Ao Instituto Federal Goiano – Campus Rio Verde e aos professores do Programa de Pós-Graduação em Bioenergia e Grãos, pelas aulas ministradas que foram de suma importância para o meu conhecimento.

Aos responsáveis pelo Laboratório de Drones e Vant na Agricultura (LDVA) do Instituto Federal Goiano – Campus Rio Verde, que nos emprestou os equipamentos necessários para os voos e processamento de imagens, e também aos Colegas do Programa em Bioenergia e Grãos pelas trocas de conhecimentos.

A GDM Genética do Brasil S.A, por ter me concedido a oportunidade de cursar o mestrado.

Ao meu gerente Franco Zanotti, por autorizar a realizar o mestrado em horários de serviço. Ao meu colega de trabalho Welton Luiz Zaluski, por me incentivar a entrar no mestrado e ajudar com a escolha do projeto.

E, gostaria de agradecer a todos que indiretamente me ajudaram nessa caminhada.

SUMÁRIO

RESUMO.....	i
1. INTRODUÇÃO.....	3
2. REVISÃO BIBLIOGRÁFICA	5
2.1 Cultura da soja.....	5
2.2 Sensoriamento remoto.....	6
2.3 Melhoramento genético da soja visando precocidade.....	7
4. MATERIAL E MÉTODOS	11
4.1 Análise estatística.....	13
6. RESULTADOS E DISCUSSÃO.....	14
7. CONCLUSÃO.....	33
8. REFERÊNCIAS BIBLIOGRÁFICAS	34

GRUPOS DE MATURAÇÃO DA CULTURA DA SOJA AVALIADOS POR IMAGENS AÉREAS OBTIDAS POR VANT

Por

JOÃO CARLOS SILVA FERREIRA

(sob orientação do Prof Dr. Pablo Diego Silva Cabral)

RESUMO

A soja é a oleaginosa de maior notoriedade econômica mundial, o Brasil tem importância significativa na sua produção. As cultivares de soja precoces são desejáveis, uma vez que possibilitam redução dos custos de produção e a realização de uma segunda safra. Empresas e universidades que trabalham com melhoramento genético têm procurado desenvolver novas cultivares, utilizando veículos aéreos não tripulados para mapear áreas por imagens aéreas sem contato direto com a planta, que auxilia nas avaliações. Este trabalho foi realizado com objetivo de avaliar a utilização de imagens aéreas para a avaliação da maturação na cultura da soja. Foram realizados 8 voos em um talhão da fazenda Retiro no município de Rio Verde- GO, com o drone Phantom 4 acoplado com sensor RGB. As imagens foram processadas no Laboratório de Drones e Vant na Agricultura do IF Goiano, Campus Rio Verde, utilizando software Pix4D e analisadas no software QGIS. Também foram obtidos dados a campo com avaliação visual das plantas seguindo o comparativo das plantas testemunhas com os grupos de maturação conhecidos. Realizou-se uma análise *boxplot*, posteriormente uma correlação entre as refletâncias RGB e o índice PRI com Grupo de Maturação (GM), além de análises de regressão linear simples e múltipla. Os dados foram divididos aleatoriamente em dois grupos: com 80% dos genótipos e o outro com 20%. Para a obtenção de modelos foi realizado no primeiro grupo uma regressão linear múltipla com todas as refletâncias e uma regressão linear múltipla *stepwise* com modelo de seleção de variáveis. O critério de seleção utilizado foi o de AIC. A regressão de *stepwise* apresentou o maior R^2 entre os modelos propostos (39,94%). Conclui-se que o modelo *stepwise* foi o melhor método de avaliação de grupos de maturação da soja, porém ainda não suficiente para garantir maior confiabilidade nos dados.

PALAVRAS-CHAVE: *Glycine max*, Drone, Estádio fenológico.

SOYBEAN CULTURE MATURATION GROUPS ASSESSED BY AERIAL IMAGES OBTAINED BY UAV

By

JOÃO CARLOS SILVA FERREIRA

(Under The Advice Of Dr. Pablo Diego Silva Cabral)

ABSTRACT

Soybeans are the most widely known oilseeds in the world, Brazil is important in its production. Precocious soybean cultivars are desirable, enabling cost reduction and a second crop. Genetic improvement companies are always creating better cultivars, using unmanned aerial vehicles for areas mapped by aerial images without direct contact with the plant which help the area evaluation. The objective was to evaluate the use of aerial images to assess plant maturation. Eight flights were carried out in a plot of the Retiro farm in the municipality of Rio Verde-GO, with the Phantom 4 drone coupled with an RGB sensor. The images were processed in the Laboratory of Drones and Vant in Agriculture of the IF Goiano, Rio Verde campus, using the Pix4D software and analyzed in the QGIS software. The evaluated agronomic character was the maturation group, the data were also obtained in the field with visual assessment of the plants following the comparison of control plants with known maturation group. A boxplot analysis was performed, then a correlation was made between the RGB reflectance and the PRI index with Maturation Group (GM), simple and multiple linear regression analysis. The data were randomly divided into two groups being one with 80% of the genotypes and the other with 20%. To obtain the models that were performed in the first group, a multiple linear regression with all wavelengths and indices and a stepwise multiple linear regression with variable selection model were carried out. The variable selection criterion used was the AIC. The regression stepwise shows the highest R^2 among the proposed models, which was 39.94%. It was concluded that the stepwise model was the best method for evaluating soybean maturation groups, but it is not sufficient for greater data reliability.

KEYWORDS: *Glycine max*, Drone, Phenological stage.

1. INTRODUÇÃO

A soja é uma das principais commodities mundiais, sendo produzida em mais de 60 países, tendo como subprodutos o farelo e o óleo, que são de suma importância para a alimentação animal e humana (Conab, 2019).

No Brasil, seu cultivo ocorre predominantemente no Cerrado, na região Centro-Oeste (Silva et al., 2017). No Cerrado brasileiro, são desejáveis cultivares de soja que possuam precocidade, além da alta produtividade de grãos (Meotti et al., 2012).

A obtenção de cultivares produtivas é um dos principais objetivos do melhoramento da soja (Silva et al., 2017), e a precocidade dos cultivares é uma das principais características atualmente exigidas pelo mercado, uma vez que possibilita a redução de custos com a cultura no campo e minimiza os riscos que podem surgir em função de fatores bióticos e abióticos (Teixeira, 2017).

Isso ocorre porque os produtores da região Centro-Oeste têm a possibilidade de cultivar outras culturas em uma segunda safra, entre os meses de fevereiro e julho. Além disso, os genótipos de ciclo precoce permanecem menos tempo no campo, e estão sujeitos ao menor ataque de patógenos, pois, as doenças de final de ciclo da soja, provocam reduções consideráveis no rendimento da cultura (Finoto et al., 2014).

Existem dez genes que controlam o tempo de florescimento e maturidade, e estão relacionados com a determinação do ciclo da soja (Watanabe et al., 2012). De acordo com a Embrapa (2010), os grupos de maturação (GM) da soja variam de acordo com a latitude e são classificados por uma escala que vai de 0 (mais próximo dos polos) a 10 (mais próximo do Equador).

A caracterização da precocidade é uma atividade onerosa, que demanda tempo e mão de obra, uma vez que é necessária a contagem a campo do número de dias da emergência até o florescimento ou maturação de cada genótipo.

As empresas de melhoramento avaliam milhares de linhagens de soja anualmente, sendo o monitoramento quanto ao ciclo realizado diariamente, exigindo assim grande número de pessoas, e aumenta a possibilidade da ocorrência de erros de avaliação, já que pessoas diferentes naturalmente não têm os mesmos parâmetros de avaliação.

Veículos aéreos não tripulados (VANT's) são cada vez mais utilizados na agricultura para o sensoriamento remoto das lavouras, pois apresentam inúmeras vantagens na avaliação das culturas, como redução dos custos de coleta de dados; possibilidade de obtenção de dados de maneira segura mesmo em situações adversas; e menor gasto de treinamento de profissionais aptos para coletar dados aéreos (Longhitano, 2010).

Os sensores acoplados em VANT's possuem infinidade de aplicações avaliando fatores através da refletância emitida e quantifica por exemplo, identificação de biomassa, índice foliar, doenças causadas por fito patógenos, pragas, estresse hídrico, previsão de rendimento, monitoramento das propriedades físico-químicas do solo e mapeamento, análises químicas nas folhas, controle e gerenciamento de pragas e plantas daninhas, propriedades superficiais do solo, condições biológicas, parâmetros de clorofila, concentração de nitrogênio na folha, cobertura vegetativa, dentre outros fatores (Zhan & Kovacs, 2012).

Nas plantas de soja, os valores de refletância indicam aspectos da planta de acordo com a cor de sua refletância, a cor verde diminui pelo amarelecimento das folhas e redução da área fotossinteticamente ativa, o que ocorre no estágio R6 e, caracteriza-se como a fase final de enchimento de grãos, ou seja, as vagens ainda possuem grãos verdes, porém com suas cavidades completamente preenchidas (Embrapa, 2010).

No estágio R7 as plantas apresentam características de início de maturação, principalmente, o amarelecimento de vagens, neste caso, a planta passa a refletir mais de 30% de vermelho. Considera-se o início do estágio R7 quando pelo menos uma vagem normal no caule apresenta coloração de madura (Embrapa, 2010).

Este trabalho foi realizado com o objetivo de utilizar imagens aéreas obtidas por veículos aéreos não tripulados para prever grupos de maturação em plantas de soja nas gerações F₃, e conseguir através dessas imagens um modelo preciso de mensuração ágil e com acurácia dos grupos de maturação (GM), diminuindo erros de avaliação a campo e proporcionando que a mesma seja realizada em menor tempo.

2. REVISÃO BIBLIOGRÁFICA

2.1 Cultura da soja

A soja [*Glycine max* (L.) Merrill], originária da China, pertence à família Fabaceae e a forma silvestre não é mais encontrada na natureza (Sediyama; Teixeira; Reis, 2014). Veio para o Brasil com a chegada dos primeiros imigrantes japoneses em 1908, primeiramente foi levada para a Bahia e posteriormente foi introduzida em São Paulo, e em 1914 no Rio Grande do Sul, onde apresentou melhor adaptação devido às condições edafoclimáticas mais semelhantes aquelas das regiões tradicionais de cultivo no sudoeste da China (Campelo et al., 1998).

Passou a ser plantada em outras partes do território nacional em 1970 (Black, 2000), quando a indústria do óleo começou a ampliar com a demanda do grão, que é a matéria-prima para sua produção. Esta é considerada a oleaginosa de maior destaque econômico mundial.

Na safra 2018/2019 o Brasil era o segundo maior produtor do mundo, a safra teve a produção total mundial de 362,075 milhões de toneladas, sendo que apenas o Brasil sozinho produziu 114,843 milhões de toneladas do grão (Embrapa, 2019).

Atualmente o Brasil chegou ao posto de maior produtor de soja do mundo, produzindo sozinho 122 milhões de toneladas do grão, passando os Estados Unidos que se mantinha na liderança a anos, porém em 2020, conseguiram produzir apenas 96 milhões de toneladas do grão (Conab, 2020).

Os resultados divulgados pela Companhia Nacional de Abastecimento (Conab, 2019), apontam que a produção total mundial na safra 2019/20 foi de 339 milhões de toneladas, e o Brasil sozinho contabilizou 122 milhões de toneladas, e representa aumento de 1,6% ou 3,9 milhões de toneladas, em comparação à safra 2018/19.

Com isso, a safra atual se mantém como recorde e para a próxima safra a expectativa é que sejam cultivados 63,9 milhões hectares, aumento de 1,1% em comparação à última safra (Conab, 2020).

No Brasil, é a cultura que mais cresceu nos últimos anos e corresponde a mais de 50% da área plantada de grãos no Brasil, passando os 36 milhões de hectares (Embrapa, 2020) e vem se destacando como uma das leguminosas mais importantes e cultivadas do mundo todo (Clemente & Cahoon, 2009).

O incremento médio de 36 kg ha⁻¹ ano⁻¹ na produtividade do grão, entre as safras de 1976/77 até 2012/13, foi proporcionado principalmente pelo melhoramento genético e a expansão na área de cultivo, que totalizou naquela safra a cerca de 28 milhões de hectares, com produtividade média de 2.900 kg ha⁻¹ (Conab, 2013).

Esta oleaginosa é considerada a mais consumida e produzida, seu grão triturado resulta em farelo e óleo, que são ricos em proteínas e utilizados principalmente no consumo animal e humano através da produção de rações e óleos vegetais (Brum, 2006).

A composição aproximada dos grãos de soja é de 30 a 34% de carboidratos; entre 18 e 20% de lipídios, dos quais 23% são ácidos graxos monoinsaturados, 58% poli-insaturados e 15% saturados; e 40 a 45% de proteína. (Silva, 2005).

2.2 Sensoriamento remoto

O sensoriamento remoto (SR) busca obter informações de um objeto sem a necessidade de existir um contato físico com o mesmo. Na agricultura, as técnicas de SR consistem em usar recursos de imagem, luz visível, ultrassom ou infravermelho para obter medidas agronômicas e avaliar a cultura (Moeckel et al., 2017).

Os sensores remotos buscam coletar dados que são base para avaliações precisas. Estes sensores coletam os dados e imagens em tempo real, de maneira ágil e não destrutiva, otimizando a tomada de decisão (Zhang & Kovacs, 2012).

Tradicionalmente, as avaliações de vegetação vêm sendo realizadas através de imagens por satélite, porém dependente da periodicidade de aquisição e possuem resolução espacial na ordem de alguns metros por pixel (Campos et al., 2018).

Imagens com resolução maior pode ser adquiridas a partir de sensores orbitais, como é o exemplo do satélite GeoEye-1 (Fraser & Ravanbakhsh, 2009). No entanto, essas imagens com maior resolução são de acesso restrito e pagas.

Após o surgimento recente dos drones, seu uso foi aliado a técnicas de processamento de imagem e inteligência artificial para avaliar a vegetação e vem sendo amplamente estudados para obter informações de maneira remota (Zhang & Kovacs, 2012; Bendig et al., 2015).

A utilização de sensoriamento remoto com auxílio de veículo aéreo não tripulado (VANT's) vem sendo disseminado em todo o mundo para o mapeamento e estudo de áreas agrícolas, incluindo a produção de soja (da Silva Junior et al., 2016). A tecnologia vem se tornando cada vez mais um aliado para identificar plantas mais produtivas que serão utilizadas para aumento da produção agrícola (Mazoyer & Roudart, 2008).

Os VANTs possuem sensores que captam a refletância de luz visível emitida pela planta, que geram dados da imagem de um mesmo objeto, com diferentes refletâncias eletromagnéticas (Zarco-Tejada *et al.*, 2013).

Existem sensores que são câmeras convencionais (sensores RGB, que capturam imagens no vermelho, verde e azul) para uso em VANT que são convertidas com um filtro infravermelho diretamente no sensor para captar a refletância espectral NIR (Near Infrared) (Jensen, 2009).

Estes sensores também podem ser multiespectrais, que são um conjunto de sensores que captam em várias refletâncias espectrais como RGB do espectro visível, NIR no espectro não visível e a Red Edge, refletância espectral que se posiciona exatamente no limiar entre o visível e não visível, que podem aumentar a sensibilidade de certos índices, muito utilizado para identificar certas doenças e pragas das lavouras (Menezes & Almeida, 2012).

2.3 Melhoramento genético da soja visando precocidade

Os programas de melhoramento genético possuem a necessidade de obterem plantas mais produtivas, resistentes a pragas e doenças além da necessidade de se obter cultivares adaptadas com as diversas localidades e climas (Embrapa, 2009).

A utilização de tecnologias e de materiais genéticos de alto potencial produtivo condicionou o aumento na produtividade de grãos. Porém, torna-se necessária, para

condicionar incrementos cada vez mais compensatórios, a obtenção de materiais adaptados às condições edafoclimáticas de cada região (Torres et al., 2014).

A duração das fases e do ciclo de desenvolvimento da soja são regulados por temperatura e fotoperíodo (Kantolic, 2008), e o desenvolvimento das cultivares com grupos de maturação baixos são mais dependentes da temperatura do ar elevada que do fotoperíodo até o início do enchimento de grãos (Sinclair et al., 2005).

O fotoperíodo e a temperatura, exercem influência sobre a floração e a taxa de desenvolvimento da soja, com reflexos sobre a estatura de planta, o ciclo e o potencial de produtividade da cultura (Jiang *et al.*, 2011).

De acordo com a Embrapa (2014), os fatores climáticos afetam o desenvolvimento das plantas de soja, uma temperatura ideal para seu desenvolvimento é entre 20 a 30°C. Em relação a floração é necessária temperatura acima de 13°C no período de maturação, temperaturas muito altas com excesso de umidade podem contribuir para diminuição na qualidade do grão, quando associadas a condições de baixa umidade, aumentam os riscos de danos mecânicos durante a colheita.

Temperaturas baixas na fase da colheita, associadas a períodos chuvosos podem provocar atraso na data da colheita, além de haste verde e retenção foliar. A necessidade total de água na cultura da soja, para obtenção do máximo rendimento, varia entre 450 a 800 mm/ciclo (Embrapa, 2014).

A radiação solar está relacionada com a fotossíntese, alongação de haste principal e ramificações, expansão foliar e fixação biológica; para o total de fitomassa seca produzida pela soja, depende da percentagem de radiação fotossinteticamente ativa interceptada e da eficiência de utilização dessa energia pelo processo fotossintético (CÂMARA, 2000).

Os programas de melhoramento de soja buscam a seleção de genótipos com características que permitam rendimentos maiores em menor tempo e com alta resistência a fatores de estresse (Martins *et al.*, 2016).

A recomendação de genótipos específicos para cada ambiente, a estratificação de uma área heterogênea em subregiões mais homogêneas e a identificação de genótipos com ampla adaptabilidade e estabilidade, tem sido as alternativas propostas aliadas com o

melhoramento genético para diminuir o efeito da interação genótipos/ambientes e aumentar a produção agrícola (Pelúzio et al., 2005).

Para isso são selecionadas linhagens mais produtivas, resistentes a pragas, doenças, adaptadas a diferentes condições de clima, solo, fotoperíodo e que permitam a incorporação de novas áreas, possibilitando maior rentabilidade para o produtor (Vasconcelos et al., 2012).

A utilização de sementes com alta qualidade genética, física e fisiológica é fundamental na obtenção de resultados satisfatórios em culturas de expressão econômica (Carvalho & Nakagawa, 2012).

A seleção visando a melhoria da qualidade fisiológica de sementes de soja também pode ser uma característica de grande importância para os programas de melhoramento genético (Vasconcelos et al., 2012).

As empresas de melhoramento genético estão a todo momento desenvolvendo novas cultivares e buscando otimizar suas avaliações para que as novas linhagens cheguem ao produtor final rapidamente

A soja possui vários estádios de desenvolvimento que se dividem em duas fases: vegetativa (V) e reprodutiva (R) (Figura 1). Subdivisões da fase vegetativa são designadas numericamente como V1, V2, V3, até Vn, menos os dois primeiros estádios que são designados como VE (emergência) e VC (estádio de cotilédone).

O último estágio vegetativo é designado como Vn, em que “n” representa o número do último nó vegetativo formado por um cultivar específico.

Os oito estádios R (reprodutivos) são divididos em quatro partes: R1 e R2 descrevem o florescimento; R3 e R4 o desenvolvimento da vagem; R5 e R6 o desenvolvimento da semente e R7 e R8 a maturação da planta.

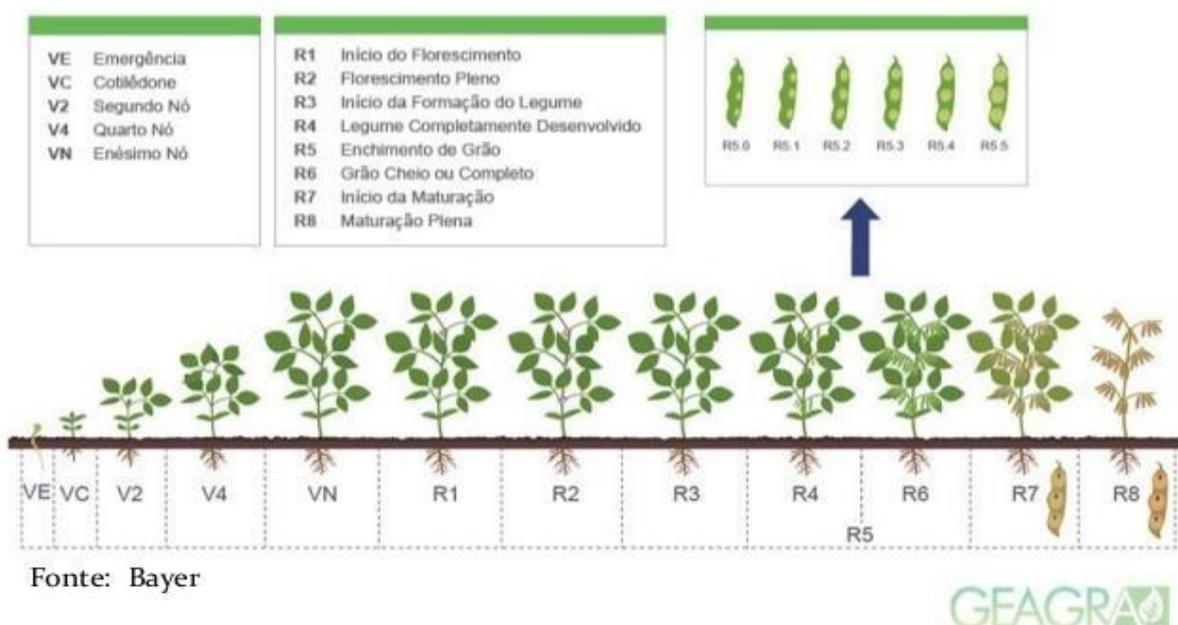


Figura 1 – Fases fenológicas da cultura da soja

O desenvolvimento da planta está diretamente relacionado ao aumento de sua biomassa até o estágio de R5, pela maior área verde tendo maior reflectância da cor verde na faixa do visível. A maior biomassa resulta em aumento da taxa fotossintética e, consequentemente, maior absorção de CO₂ atmosférico (Beltrão et al., 2007).

Neste sentido, técnicas de sensoriamento remoto surgem como instrumento de elevado potencial, fornecendo informações específicas e confiáveis com relação ao estado das lavouras (Mercante et al., 2010), diminuindo erros de avaliação da predição do estágio vegetativo da planta.

Para fornecer informações das lavouras criando modelos de avaliações do estágio fenológico da planta para predição de época de colheita, utiliza-se índices que representam a resposta espectral da vegetação na região do espectro visível (Gonzalez & Woods, 2010).

3. MATERIAL E MÉTODOS

O experimento foi conduzido na Fazenda Retiro (17°42'27.6"S 50°48'50.4"W), em um talhão experimental da empresa GDM Genética do Brasil, município de Rio Verde - GO, no período de dezembro de 2018 a fevereiro de 2019. O clima da região de acordo com a classificação de Koppen (1900) e adaptada por Setzer (1966) é do tipo definido como tropical úmido, com estação chuvosa no verão e seca no inverno (AW).

Foi retirado uma amostra de solo para a realização da análise química (Figura 2). Constatou-se que não era necessário fazer calagem do solo, pois a saturação por bases já estava ideal para o padrão da cultura.

As linhas de semeadura foram abertas com semeadora adubadora a vácuo de 8 linhas da marca John Deere e os espaçamentos entre linhas foi de 0,5 metro, utilizando 350 kg ha⁻¹ do formulado 02-25-25 (N-P-K). O tamanho útil da parcela foi de 2 linhas de 2,5 metros com uma média de 14 plantas emergidas por metro.

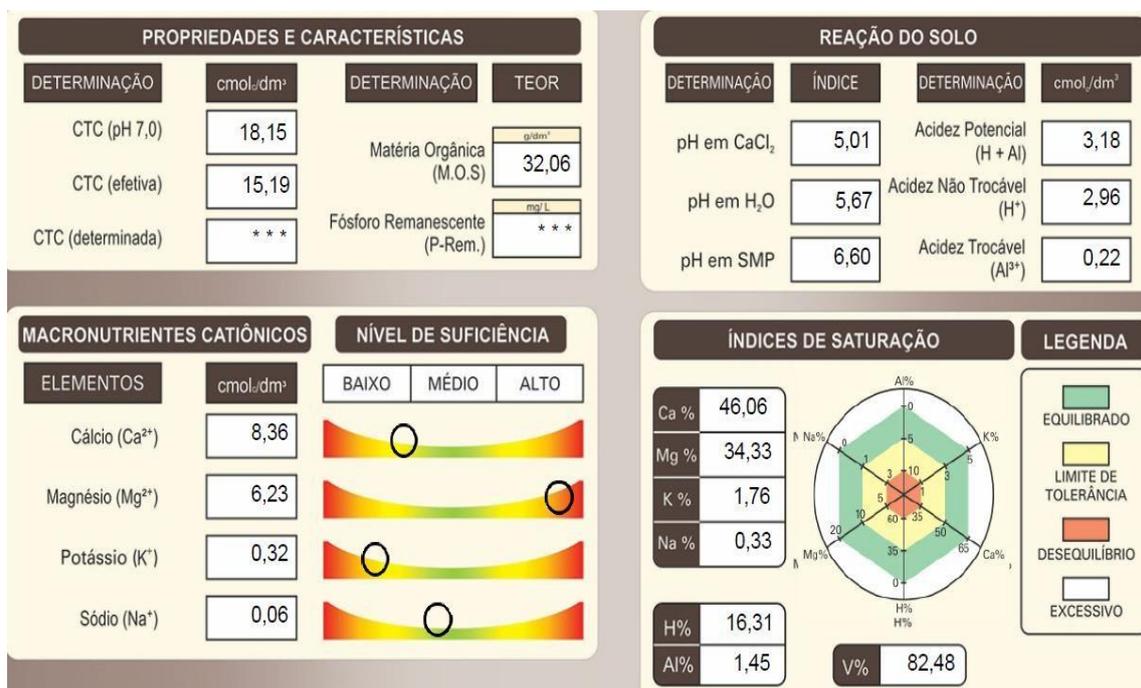


Figura 2 – Análise química do solo

O experimento foi instalado em delineamento de blocos aumentados de Federer (1956), tendo 5 blocos com 600 tratamentos em cada bloco totalizando 3000 tratamentos entre linhagens em geração F3 e testemunhas. As testemunhas se repetem ao longo dos

blocos por não possuir repetições entre os tratamentos as testemunhas são utilizadas para realizar as análises de variância tendo 30 testemunhas.

As testemunhas são BMX 62I66 com ciclo de 105 dias e grupo de maturação 6.6, BMX 68I68 com ciclo de 108 dias e grupo de maturação de 6.8, DM 68I69 com ciclo de 108 dias e grupo de maturação de 6.8, BMX 73I70 com ciclo de 114 dias e grupo de maturação de 7.3, AS3730 ciclo de 114 dias e grupo de maturação de 7.3, M-SOY7110 com ciclo de 110 dias e grupo de maturação 7.0 e NS6906 com ciclo de 109 dias e grupo de maturação de 6.9.

Foram realizados oito voos com o drone Phantom 4 acoplado com sensor RGB, em que um único sensor obtém as imagens nas refletâncias: Red, Green, Blue. Os voos foram aos 87, 91, 94, 98, 101, 108, 112 e 119 dias após a semeadura (DAS), o primeiro voo foi realizado a partir do momento que os primeiros tratamentos começaram a senescer, então, realizou-se o primeiro voo, para não perder o grupo das variedades mais precoces, em seguida o planejamento foi realizado com voos a cada 3 ou 4 dias por ser o tempo de mudança de um grupo de maturação a outro.

O planejamento de voo foi realizado utilizando o aplicativo FieldAgent (Senterra, Inc., Minneapolis, MN), com altura de voo de 30 m e sobreposição frontal e lateral de 80% para garantir boa qualidade do mosaico no pós-processamento das imagens. Essa altura permitiu obter uma resolução espacial de 3 cm para todas as refletâncias.

As imagens foram processadas no Laboratório de Drones e Vant na Agricultura (LDVA) do Instituto Federal Goiano, campus Rio Verde, utilizando o software Pix4D (Pix4D 3.2.23, Pix4D SA, Lausanne, Suíça) e analisadas no software QGIS (QGIS Development Team, 2017).

A partir das refletâncias obtidas foi calculado o índice de vegetação PRI (Índice de refletância fotoquímica), representado pela equação $PRI = (R_{GREEN} - R_{BLUE}) / (R_{GREEN} + R_{BLUE})$, (Gamon et al., 1997).

O valor da refletância dos pixels e índices de vegetação foram obtidas a partir de um desenho de uma área de interesse de 1 x 0,50 m em cada linha da parcela. Cada ponto de amostragem foi representado por uma média aritmética dos valores de refletância dos pixels na área de 0,50 m².

O caráter agrônomico avaliado foi o grupo de maturação fisiológica das plantas de soja. Esses dados foram obtidos a campo realizado pela empresa, por meio de uma avaliação visual das plantas seguindo o comparativo com as plantas testemunhas que já possuem grupo de maturação conhecido e serviram como base para avaliação das linhagens.

Foram classificados 7 grupos de maturação a campo de acordo com o número de dias para R8 e através das refletâncias RGB foi possível realizar a discriminação dos tratamentos padrões (testemunhas), para cada grupo de maturação correspondente gerando funções discriminantes, para classificar as demais linhagens quanto ao grupo de maturação.

Análises estatísticas

Realizou-se uma análise de boxplot, com limite superior (LS), terceiro quartil (Q3), mediana (Md), primeiro quartil (Q1) e o limite inferior (LI). Também foi realizado uma análise de *outlier*, em que se considerou *outlier* valores superiores a $1,5 * AIQ$ e inferiores a $1,5 * -AIQ$ ($AIQ = Q3 - Q1$) e os genótipos que tinham esses valores foram retirados, sendo AIQ: critério de informação de Akaike

A correlação entre as refletâncias Red (R), Green (G) e Blue (B) e o índice PRI com o Grupo de Maturação (GM) foi obtida. Assim como, a análise de regressão linear simples entre as refletâncias RGB e o índice PRI (variável independente) e o Grupo de Maturação (GM) para todos os oito voos e análise de regressão linear múltipla para cada voo.

Para essas análises dos 3000 mil genótipos, 414 foram considerados *outliers* e retirados do restante das avaliações, restando 2586. Posteriormente, após retirar os *outlier* que foram 414, os dados foram divididos aleatoriamente em dois grupos: um contendo 80% dos genótipos (2069 genótipos) e o outro com 20% (517 genótipos).

Para a obtenção de modelos matemáticos foi realizado no primeiro grupo com 80% dos dados uma regressão linear múltipla com todas as refletâncias e todos os índices dos oito voos e uma regressão linear múltipla *stepwise* com modelo de seleção de variáveis forward.

Esse tipo de regressão começa vazia e vai adicionando variável por variável de acordo com a melhoria do modelo. O critério de seleção de variáveis utilizado foi o de Critério de Informação de Akaike (AIC) (UPTON e FINGLETON, 1985), sendo expresso:

$$AIC = -2 * LMV + 2K, \text{ em que:}$$

LMV é logaritmo da máxima verossimilhança e;

K= número de coeficientes de regressão.

Sendo adicionado ao modelo a variável que tiver o menor AIC.

Os dois modelos obtidos (regressão linear múltipla e regressão linear múltipla *stepwise*) foram testados no grupo contendo 20% das linhagens para verificar a precisão na predição do Grupo de maturação (GM) dos mesmos.

RESULTADOS E DISCUSSÃO

Os diferentes grupos de maturação foram observados de acordo com as diferentes reflectâncias, mostrando os grupos de maturação de cada parcela (Figura 4). Os grupos maturação que refletiam luz vermelha possuíam plantas de desenvolvimento precoce, enquanto as plantas mais tardias ainda refletiam luz verde.

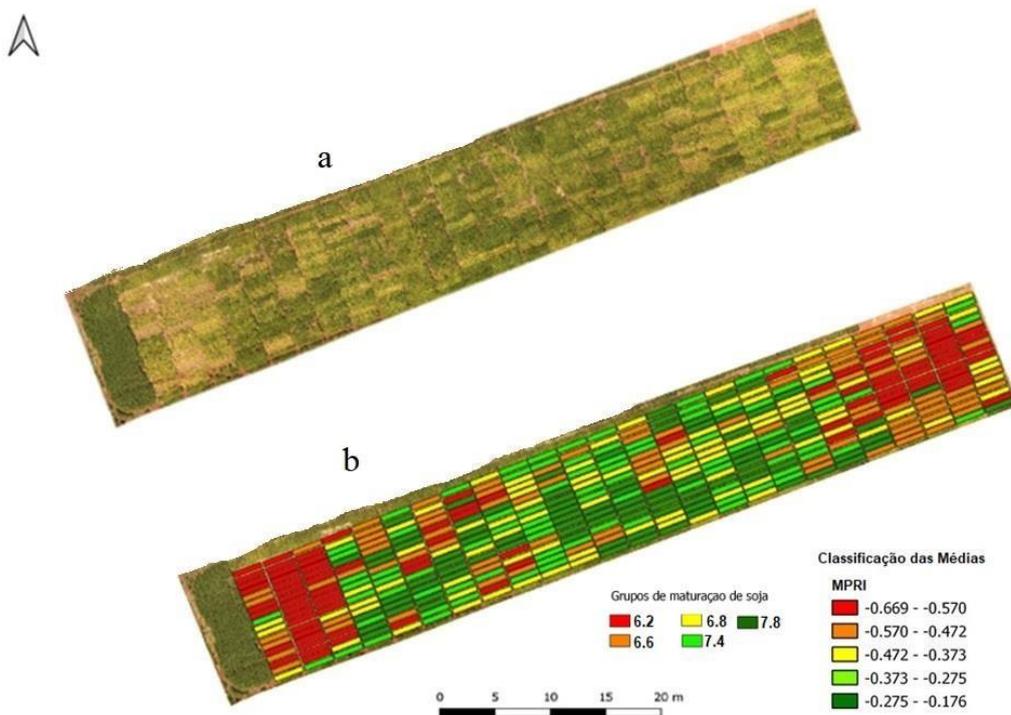


Figura 4 – Imagem aérea do campo experimental (A), imagem mostrando os grupos de maturação de cada parcela do ensaio separadamente (B).

Na figura 5 estão apresentados os *boxplots* das refletâncias Red (R), Green (G) e Blue (B) e o índice de vegetação fotossintético (PRI). Para a refletância R no *boxplot* (Figura 5A), observou-se que a mediana variou entre 105,66 a 148,94 nm para o voo1 e voo6, respectivamente. Observou-se ainda que houve aumento da mediana até o voo 6, e, após houve diminuição.

Na refletância G (Figura 5B), os dados se mantiveram na média de 110nm a 120nm com baixa variação entre os 8 voos. Na refletância B (Figura 5C), os dados se mantiveram com média entre 50 nm nos voos de 1 a 5 e tiveram aumento constante de 60, 70 e 80nm a partir dos voos 6, 7 e o 8 respectivamente.

No índice PRI (Figura 5D), houve uma variação nos valores que inicialmente estavam em -0,38 no primeiro voo e foram decrescendo até o quinto voo com valores de -0,4 e voltaram a subir a partir do sexto voo com valores de -0,3 e chegando no voo 8 com valor de - 0,1, constatando assim aumento da refletância no momento de maturação das plantas.

Oliveira-seco (2014), constatou que as características biológicas das plantas como estágio fenológico e teor de clorofila, influenciou em diferentes comportamentos

espectrais, que o aumento nos níveis de pigmentos das plantas influencia a refletância da planta na faixa do visível, cultivares mais precoces refletiram a cor vermelha mais cedo, pois chegavam antes no estágio reprodutivo e em seu amadurecimento do que cultivares mais tardias.

A refletância da planta está relacionada ao teor de clorofila, que é maior na cor verde nas fases vegetativas da cultura e decresce no amadurecimento da planta, que investe em carotenoides ao longo do ciclo para dissipar energia e poder passar por todos os seus estádios fenológicos sem senescer antes do enchimento completo dos grãos, estando associado diretamente com a atividade fotossintética e pode ser obtido através da refletância da vegetação causada pela clorofila ou pigmentos fotossintéticos presentes (GITELSON; GRITZ; MERZLYAK, 2003).

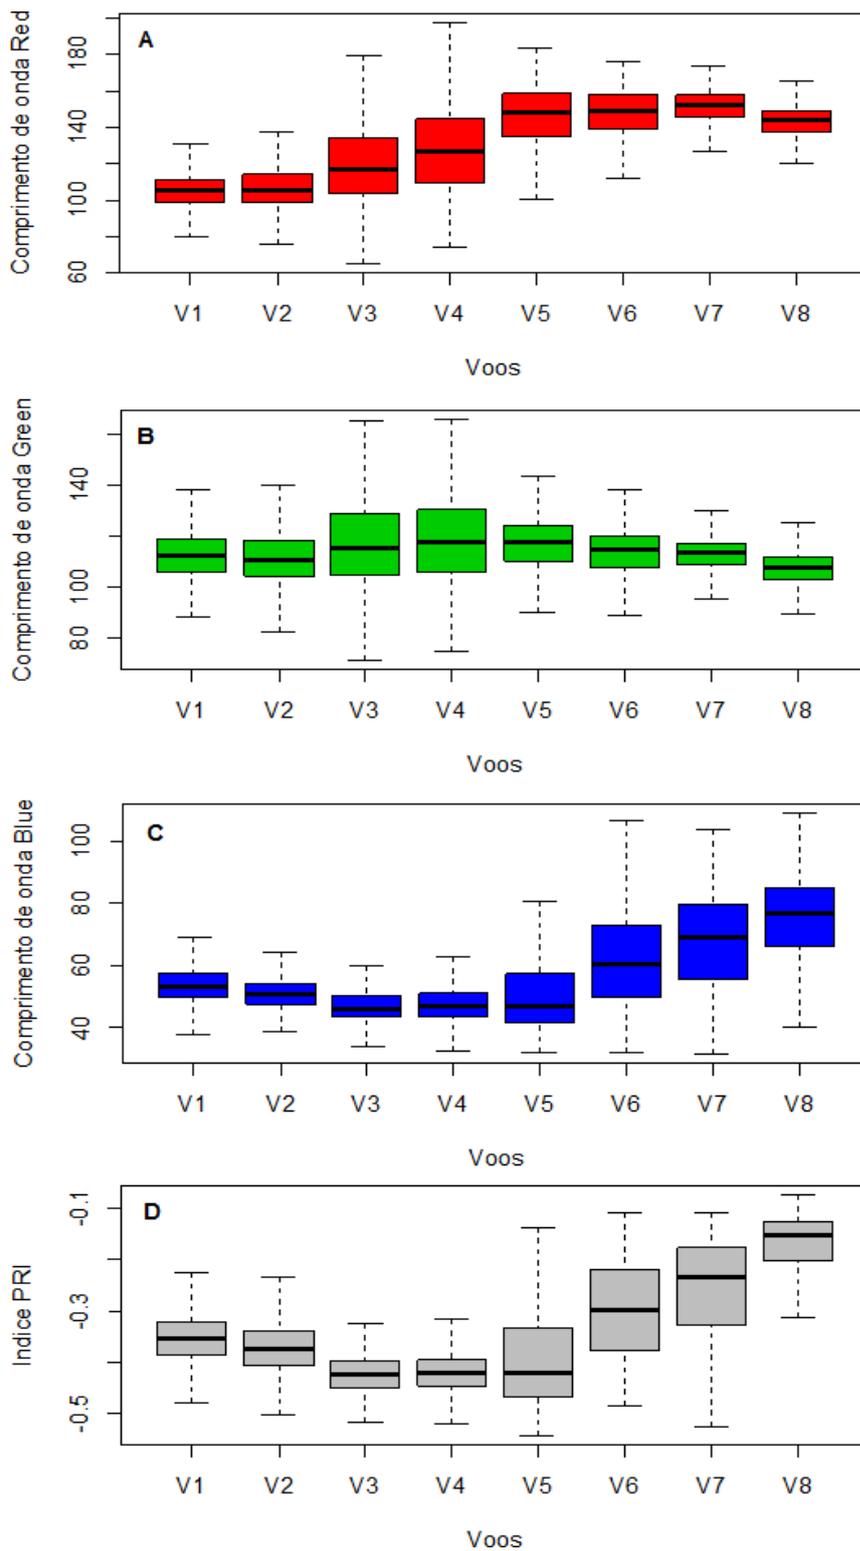


Figura 5 – Boxplot com 80% dos genótipos das refletâncias Red (A), Green (B) e Blue (C) e o índice PRI (D). Limite superior, terceiro quartil, mediana, primeiro quartil e limite inferior

É comum definir um intervalo para classificar a correlação que pode ser, muito alta (0,9 a 1), alta (0,7 a 0,9), moderada (0,5 a 0,7), correlação fraca (0,3 a 0,5) ou sem correlação (<0,3) (Mukaka, 2012).

Para a refletância R (Figura 6A), no voo 1 e 2 o valor iniciou em -0,25 mostrando que foi um valor baixo, que não representa correlação. Do terceiro ao último voo, obteve-se valores ainda menores.

Na refletância G (Figura 6B), inicialmente se tem um padrão semelhante a refletância R, com a correlação no primeiro e segundo voo de -0,25, no terceiro voo de -0,4 porém a partir do quarto voo, até os últimos valores sofrem pequeno aumento passando a -0,35, oscilando novamente a -0,25.

A refletância B (Figura 6C), apresentou valores positivos nos voos 1 e 2, e decrescem no voo 3 (-0,2) até o voo 7 com -0,5 e no último voo e sofre um pequeno aumento retornando a -0,3. O índice PRI (Figura 6 D) apresentou nos 4 voos iniciais os seguintes resultados, primeiro e segundo voo foi de 0,4, no terceiro de 0,3 e no quarto teve valor zero.

A partir do voo 5 os valores voltam a ser negativos com valor de -0,4 no voo 5, no voo 6 foi de -0,5, no voo 7 foi de -0,6 e no último voo houve leve aumento da correlação voltando a -0,3.

A correlação linear simples (Figura 6) entre as refletâncias R, G, B com o Grupo de maturação (GM) se manteve negativa em praticamente todos os voos, com apenas dois voos na refletância B sendo positivos.

Isto indica que a correlação foi muito fraca ou que não existiu correlação entre os dados, mostrando alta variabilidade de informações impossibilitando criar um padrão entre as variáveis analisadas, isso ocorre pois são várias linhagens distintas com diferentes GM, e o modelo não consegue correlacioná-las pois elas apresentaram sempre estádios fenológicos diferentes em todos os voos.

O Índice de Vegetação Fotossintético (PRI) expressa a relação entre as refletâncias do verde e azul, pode ser relacionado com a taxa fotossintética (Rahman et al, 2001). Nas folhas, o índice PRI varia com a capacidade fotossintética, uso de radiação eficiente e tipo de vegetação.

Os casos com os valores do índice PRI reduzidos seguem a hipótese que a vegetação está exposta a luz porém reduzindo a fotossíntese durante períodos de stress, e investindo, em processos de fotoproteção (Gamon et al., 1997), o que ocorre no processo de

maturação das plantas de soja, que passam a direcionar sua energia para o enchimento de grãos, param de investir em crescimento e começam a se preparar para o processo de senescência.

Percebe-se que a correlação da refletância vermelho, verde, azul e o índice de PRI com o GM é fraca ou não existe, comparado entre os 8 voos realizados, e mostra que em cada voo as plantas apresentavam diferentes estádios de desenvolvimento e refletiam as cores de acordo com seu estádios de desenvolvimento.

No trabalho de Coltri et al.; (2009), com plantas de cafeeiro, percebeu-se que os valores de PRI deram negativos em todos os talhões, e variaram entre -0,44 e -0,67, assim como neste trabalho, isso significa que a vegetação estudada estava realizando fotossíntese, com diferentes eficiências de utilização da radiação ativa e indica que as plantas estavam em diferentes fases fenológicas.

Cada teste de correlação apresenta um coeficiente individualizado, que demanda uma interpretação própria. De forma geral, para os coeficientes r de Pearson(1892), valores entre 0 e 0,3 (ou 0 e -0,3) são biologicamente desprezíveis; entre 0,31 e 0,5 (ou -0,31 e -0,5) são correlações fracas; entre 0,51 e 0,7 (ou -0,51 e -0,7) são moderadas; entre 0,71 e 0,9 (ou -0,71 e 0,9) são correlações fortes; e $> 0,9$ (ou $< -0,9$) são consideradas muito fortes

Segundo LIRA (2004), a correlação linear fornece um índice, indicando como as variáveis variam conjuntamente, comparando os dados e medindo a intensidade e a direção da relação linear ou não entre variáveis. É um indicador que atende à necessidade de se estabelecer a existência ou não de uma relação entre variáveis sem que, para isso, seja preciso o ajuste de uma função matemática.

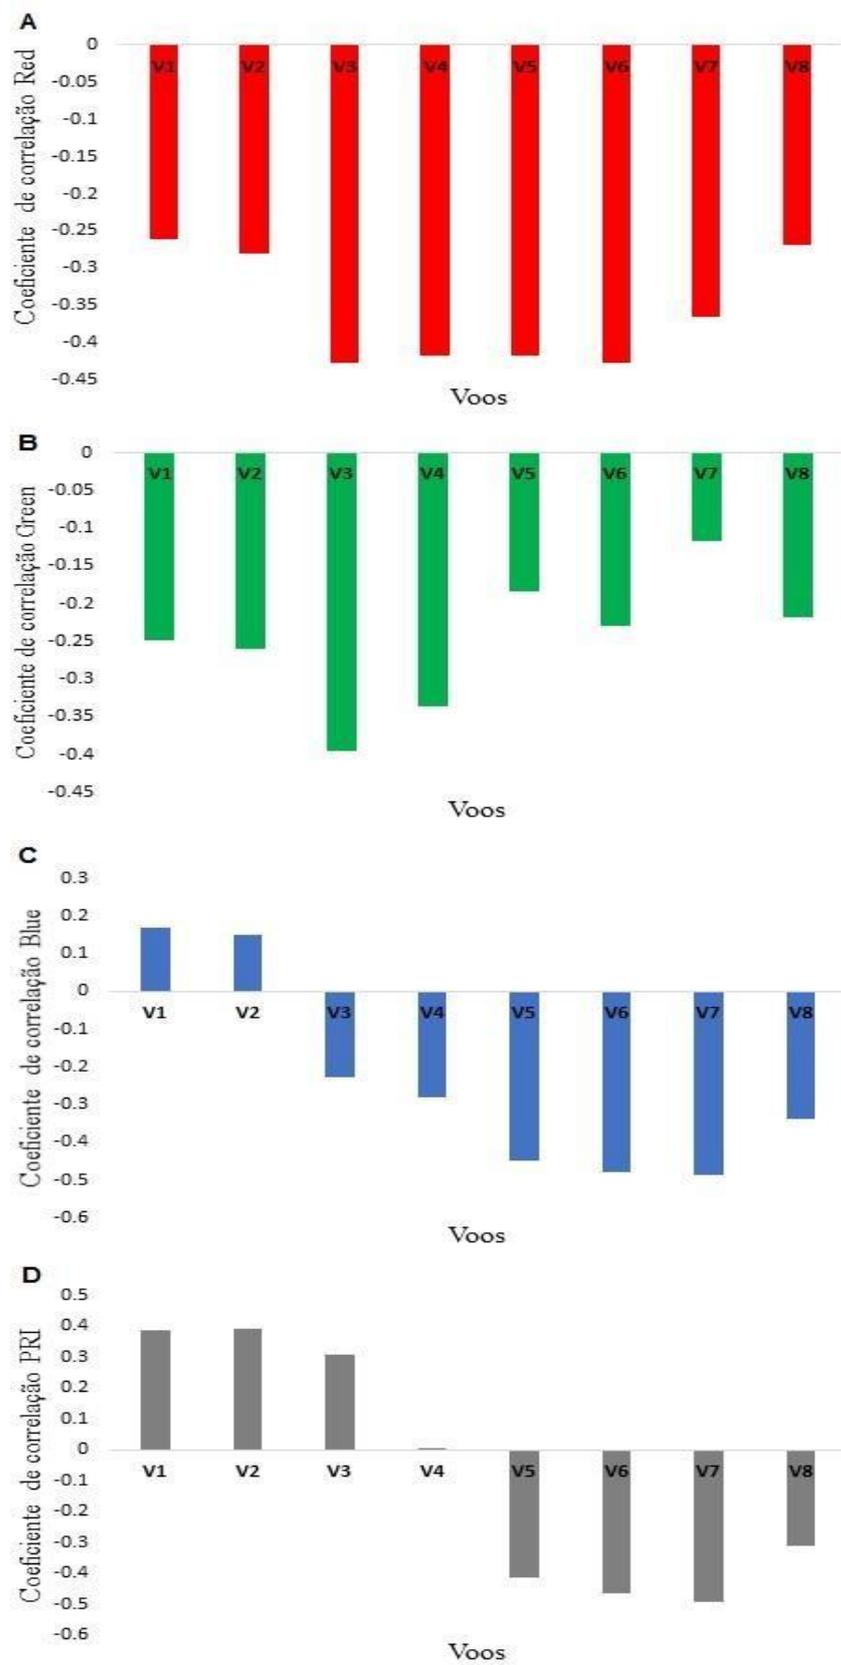


Figura 6 - Correlações entre as refletâncias Red (A), Green (B) e Blue (C) e o índice PRI (D) com o grupo de maturação

Na regressão linear simples (Tabela 1), os dados foram comparados apenas entre os valores já conhecidos e os índices avaliados para a predição do grupo de maturação. Todas as refletâncias (tanto no RGB, quanto índice PRI) foram significativas em praticamente todos os voos, apenas no voo 4 o índice PRI, não se mostrou significativo em relação aos demais.

O modelo para estimativa do GM de cultivares de soja foi determinado a partir de todas as refletâncias espectrais do visível (RGB) e o índice de vegetação PRI, referente as datas de realização de cada voo. Isso significa que os estádios de maturação das plantas de soja afetaram as refletâncias do visível (RGB).

Segundo Charnet et al. (1999), o coeficiente de determinação (R^2) serve como medida de ajuste de modelos estatísticos e demonstra a proporção de variabilidade dos dados que é explicada pelo modelo e mede a parcela da variação de Y explicada pela variação dos X.

A regressão linear consiste na análise de dados amostrais, para uma determinada população, de forma a determinar a relação entre as variáveis dependentes e independentes. O produto dessa análise é uma equação que descreve o relacionamento entre as variáveis em termos matemáticos. A regressão linear múltipla envolve três ou mais variáveis (Stevson, 1981).

Assim, observou-se que o R^2 da refletância R variou de 0,064 a 0,18, na refletância G variou de 0,058 a 0,14 e na refletância B variou de 0,023 até 0,228 e no índice PRI 0,001 a 0,234, o R^2 do trabalho se mostrou baixo, pois os valores devem variar de 0 a 1, quanto mais perto de 1 mais explicativo é o modelo linear, todos os valores do trabalho se mantiveram longe de 1.

Tabela 1 - Regressão linear simples com valores de R² para as refletâncias espectrais e índice PRI testados para estimativa de grupo de maturação através dos oito voos individualmente.

Voo1				
	Red1	Green1	Blue1	PRI1
Equação	81.152-0.0868**	81.574-0.084**	66.335+0.105**	82.921+30.813**
R ²	0.064	0.058	0.028	0.146
Voo2				
	Red2	Green2	Blue2	PRI2
Equação	78.958-0.0642**	80.11-0.072**	67.102+0.094**	82.450+28.290**
R ²	0.074	0.063	0.023	0.15
Voo3				
	Red3	Green3	Blue3	PRI3
Equação	79.85-0.064**	81.466-0.080**	77.998-0.125**	83.743+27.972**
R ²	0.173	0.148	0.048	0.09
Voo4				
	Red4	Green4	Blue4	PRI4
Equação	80.087-0.063**	80.78-0.074**	77.474-0.111**	72.226+0.607ns
R ²	0.169	0.111	0.077	0.001
Voo5				
	Red5	Green5	Blue5	PRI5
Equação	84.689-0.088**	80.117-0.069**	78.534-0.127**	65.603-16.192**
R ²	0.172	0.036	0.189	0.16
Voo6				
	Red6	Green6	Blue6	PRI6
Equação	86.204-0.098**	81.305-0.082**	79.217-0.116**	66.513-18.354**
R ²	0.18	0.052	0.216	0.204
Voo7				
	Red7	Green7	Blue7	PRI7
Equação	89.399-0.116**	78.358-0.056**	79.968-0.118**	67.283-18.052**
R ²	0.132	0.013	0.228	0.234
Voo8				
	Red8	Green8	Blue8	PRI8
Equação	87.469-0.109**	84.045-0.112**	79.377-0.098**	69.013-16.499**
R ²	0.072	0.046	0.112	0.095

** significativo e ns não significativo pelo teste F. R², coeficiente de determinação

Na regressão linear múltipla (Tabela 2), analisou-se as refletâncias e o índice vegetativo para a predição do grupo de maturação em conjunto para cada voo. O intercepto é quando as variáveis se cruzam nos eixos. As refletâncias no R e G foram significativos em todos os voos, exceto na refletância R no voo 7 que não obteve significância. A refletância B se mostrou significativo apenas no voo 4.

O índice PRI não foi significativo nos voos 2 e 5, porém foi significativo a 5% no voo 2, enquanto os demais dados foram significativos a 1%. O coeficiente de determinação da regressão linear múltipla representou o R^2 de cada voo, que no voo 1 foi de 0,173, no voo 2 de 0,172, no voo 3 de 0,208, no voo 4 de 0,236, no voo 5 de 0,227, no voo 6 de 0,249, no voo 7 de 0,241 e no voo 8 de 0,115.

Nenhum dos valores em nenhum voo chegou próximo a 1, mostrando que não há como gerar um modelo linear múltiplo para avaliação dos grupos de maturação.

Tabela 2 - Regressão linear múltipla para cada voo (80% dos dados) com valores de R^2 para as refletâncias espectrais e índice de vegetação testados para estimativa de grupo de maturação através de oito voos individualmente.

Voo1					
Intercepto	red1	green1	blue1	pri1	R^2
83.356**	-0.203**	0.155**	0.029 ^{ns}	25.395**	0.173**
Voo2					
Intercepto	red1	green1	blue1	pri1	R^2
77.846**	-0.110**	0.072*	0.083 ^{ns}	16.785 ^{ns}	0.172**/
Voo3					
Intercepto	red1	green1	blue1	pri1	R^2
82.215**	-0.146**	0.132**	0.001 ^{ns}	19.192*	0.208**
Voo4					
Intercepto	red1	green1	blue1	pri1	R^2
90.337**	-0.200**	0.296**	-0.207**	42.964**	0.236**
Voo5					
Intercepto	red1	green1	blue1	pri1	R^2
75.500**	-0.095**	0.050 ^{ns}	0.014 ^{ns}	-9.188 ^{ns}	0.227**
Voo6					
Intercepto	red1	green1	blue1	pri1	R^2
76.394**	-0.097**	0.057*	0.003 ^{ns}	-10.260*	0.249**
Voo7					
Intercepto	red1	green1	blue1	pri1	R^2
70.413**	-0.006 ^{ns}	-0.060*	0.045 ^{ns}	-23.633**	0.241**
Voo8					
Intercepto	red1	green1	blue1	pri1	R^2
74.010**	0.053**	-0.114**	-0.005 ^{ns}	-17.008*	0.115**

** , * significativo 1 e a 5% e ns não significativo pelo teste F, respectivamente. R^2 : coeficiente de determinação

A regressão linear múltipla completa (Tabela 3) é uma generalização da regressão linear simples, a maioria não foi significativa e houve diferença significativa apenas nas refletâncias R nos voos de 1 a 6, no voo 4, as refletâncias G, B e o índice PRI mostraram diferença estatística.

No voo 7 apenas o índice PRI apresentou diferença, os demais voos e refletância não tiveram diferença estatística, porém com a regressão múltipla o R^2 foi maior do que na regressão simples, com valor de 0,3745, mostrando que o modelo é melhor para avaliação dos dados do que a regressão linear simples, pois obteve resultado mais alto.

Tabela 3 - Regressão linear múltipla completa (80% dos dados).

Refletância e IV's	Coefficiente de regressão	Refletância de onda e IV's	Coefficiente de regressão
Intercepto	71.659**	red5	-0.032**
red1	-0.082**	green5	0.013 ^{ns}
green1	0.037 ^{ns}	blue5	0.045 ^{ns}
blue1	0.063 ^{ns}	pri5	-7.780 ^{ns}
pri1	-3.304 ^{ns}	red6	-0.031*
red2	-0.032*	green6	0.011 ^{ns}
green2	-0.007 ^{ns}	blue6	0.007 ^{ns}
blue2	0.078 ^{ns}	pri6	-3.092 ^{ns}
pri2	-4.261 ^{ns}	red7	-0.029 ^{ns}
red3	-0.032*	green7	-0.047 ^{ns}
green3	0.011 ^{ns}	blue7	0.104*
blue3	0.066 ^{ns}	pri7	-17.543**
pri3	-5.969 ^{ns}	red8	-0.002 ^{ns}
red4	-0.057**	green8	-0.047 ^{ns}
green4	0.114**	blue8	0.044 ^{ns}
blue4	-0.109*	pri8	-8.720 ^{ns}
pri4	17.359**		
Coefficiente de determinação ajustado (R_a^2)		0,3745**	
Equação de regressão: $71.659 - 0.082 \times \text{red1} + 0.037 \times \text{green1} + 0.063 \times \text{blue1} - 3.304 \times \text{pri1} - 0.032 \times \text{red2} - 0.007 \times \text{green2} + 0.078 \times \text{blue2} - 4.261 \times \text{pri2} - 0.032 \times \text{red3} + 0.011 \times \text{green3} + 0.066 \times \text{blue3} - 5.969 \times \text{pri3} - 0.057 \times \text{red4} + 0.114 \times \text{green4} - 0.109 \times \text{blue4} + 17.359 \times \text{pri4} - 0.032 \times \text{red5} + 0.013 \times \text{green5} + 0.045 \times \text{blue5} - 7.780 \times \text{pri5} - 0.031 \times \text{red6} + 0.011 \times \text{green6} + 0.007 \times \text{blue6} - 3.092 \times \text{pri6} - 0.029 \times \text{red7} - 0.047 \times \text{green7} + 0.104 \times \text{blue7} - 17.543 \times \text{pri7} - 0.002 \times \text{red8} - 0.047 \times \text{green8} + 0.044 \times \text{blue8} - 8.720 \times \text{pri8}$			

**,* e ns significativo a 1 e a 5% e não significativo pelo teste F.

Na regressão linear múltipla *stepwise* (Tabela 4) com seleção de variáveis com modelo *forward*, a regressão começa vazia e vai adicionando as variáveis de acordo com

o menor AIC, que é uma medida relativa da qualidade de ajuste de modelo estimado. Assim, a primeira variável a ser inserida foi a PRI7 com AIC de 6811,11 (Tabela 4), corroborando com os dados da Figura 6, em que se observou que essa variável teve a maior correlação com o GM.

Com esse, critério foram adicionadas mais 21 variáveis com o AIC terminando em 5618,83 e a adição de novas variáveis não melhora o ajuste do modelo, pois mesmo com mais variáveis os resultados são semelhantes ao com menos variáveis utilizadas (Miranda; Melo; Sanqueta, 2011).

Das 22 variáveis adicionada ao modelo, apenas 4 (PRI2, Blue6, Green7 e Green8) não foram significativas pelo teste t., porque o modelo de inserção de variáveis adotado não leva em conta o teste t, mas sim o menor AIC.

Ao comparar o R^2 dos dois modelos, regressão linear múltipla (Tabela 3) e regressão linear múltipla *stepwise* (Tabela 4), observa-se que há alta similaridade entre os dois, 0,3745 e 0,3748, respectivamente. Por outro lado, quando se compara o número de variáveis dos modelos, observa-se que o método *stepwise* possui um número menor de variáveis, 22 contra 28.

Dentre as variáveis adicionadas no modelo (Tabela 4), pode-se observar que sete foram PRI, seis R, cinco B e quatro G e demonstra a maior importância do índice PRI e do Red na melhoria do modelo. O índice está diretamente ligado a maior taxa fotossintética (Rahman et al, 2001).

Assim, quando as cultivares evoluem no ciclo, a taxa fotossintética tende a diminuir o que se pode observar na Figura 6, em que o menor PRI é o do voo7, mostrando já a baixa relação entre o G e B, e a menor dissipação de energia que é vista pelo R nos voos 6 e 7. A luz vermelha é refletida pela planta em forma de dissipação de energia da luz azul captada, que poderia provocar excesso de calor na planta causando situação de estresse luminoso (Junior-Fonseca, 2018).

Quando se compara os voos entre as duas metodologias, observa-se que o voo que teve todas as suas variáveis incluídas no modelo foi o voo 7, as plantas já estavam com esse estágio fenológico avançado em fase de maturação.

Em algumas plantas apresentaram refletância das clorofilas (green) realizando fotossíntese para finalizar o enchimento dos grãos em plantas tardias, porém se teve valores altos de refletância (red e blue) e no índice PRI, indicando a fase de maturação da planta.

A planta busca a manutenção das clorofilas b, que refletem luz vermelha, para uma maior capacidade fotoprotetora, evitando excesso de energia e prevenindo a formação de espécies reativas de oxigênio mais eficiente, que minimizam os danos causados as células das plantas, evitando senescência precoce (Apel & Hirt, 2004).

Os voos 1, 2, 4, 5 e 6 tiveram três variáveis inseridas no modelo, isso ocorre pois inicialmente a planta na fase vegetativa está com alto teor de clorofilas, realizando fotossíntese e dissipando excesso de energia, refletindo assim as 3 refletâncias (R, G e B) e depois continua realizando fotossíntese quando entra no estágio reprodutivo para o enchimento de grãos.

No voo 3 não obteve nenhuma variável inserida no modelo, assim como o voo 4 que teve apenas a refletância B inserida, porém no voo 3 a planta estava se preparando para enchimento de grãos, mantendo parte de seus estômatos fechados para não perder água para o ambiente e realizando menor fotossíntese e consequentemente possui menor refletância. Assim, demonstra-se que com menor número de voos é possível igualar com a mesma precisão do modelo da regressão linear múltipla.

Tabela 4 - Regressão linear múltipla *stepwise* (80% dos dados)

Refletância e IV's	Coefficiente de Regressão	¹ AIC
Intercepto	76.005**	6811.11
pri7	17.681*	6120.98
blue5	0.062**	5928.67
pri2	-4.41 ^{ns}	5841.42
pri6	-4.95*	5795.27
pri1	5.112**	5766.72
red6	-0.026**	5752.47
red1	-0.088**	5738.75
green1	0.073**	5717.11
blue6	0.017 ^{ns}	5706.40
pri8	-2.509*	5698.97
red4	-0.065**	5690.44
green4	0.123**	5660.46
pri4	17.250**	5657.56
red2	-0.040**	5654.66
blue2	0.086*	5648.34
red7	-0.029*	5644.82
blue7	0.104*	5636.18
pri5	-10.70**	5634.40
red5	-0.027**	5624.52
blue4	-0.107*	5621.46
green7	-0.044 ^{ns}	5619.58
green8	-0.015 ^{ns}	5618.83
Coeficiente de determinação ajustado Ra ²		0.3748**

Equação de predição: $GM = 76.005 + 17.681 \times pri7 + 0.062 \times blue5 - 4.41 \times pri2 - 4.95 \times pri6 + 5.112 \times pri1 - 0.026 \times red6 - 0.088 \times red1 + 0.073 \times green1 + 0.017 \times blue6 - 2.509 \times pri8 - 0.065 \times red4 + 0.123 \times green4 + 17.250 \times pri4 - 0.040 \times red2 + 0.086 \times blue2 - 0.029 \times red7 + 0.104 \times blue7 - 10.70 \times pri5 - 0.027 \times red5 - 0.107 \times blue4 - 0.044 \times green7 - 0.015 \times green8$

** , * e ns significativo a 1 e a 5% e não significativo pelo teste F. ¹ Critério de informação de Akaike.

Na tabela 5 é demonstrado a porcentagem de acordo com a *stepwise* dos 20% retirados total de 517 genótipos. Cada classe representa quantos pontos de erro para mais ou para menos se teve, comparando com os valores avaliados pela empresa.

Com as quantidades de genótipos por GM avaliado e o intervalo de classes foi de $> -7,0$ a $< 7,0$, e possui uma porcentagem em cima da quantidade de genótipos avaliados, e é possível ver as variações de erro na avaliação, pois o interessante é estar em um valor zero, pois mostra que teve menor variação entre o avaliado pela empresa e o predito pela equação.

Observa-se que o modelo proposto apresentou o intervalo com $< 7,0$ um total de porcentagem de classe de 2,13%, no intervalo de 5,0 a 6,9 foi de 1,93%, no intervalo de 3 a 4,9 foi de 7,74%, no intervalo de 1 a 2,9 foi de 24,95%, no intervalo de -0,99 a 0,99 foi de 30,75%, no intervalo de -1 a -2,9 foi de 19,54%, no intervalo de -3 a -4,9 foi de 6,96%, no de -5 a -6,9 foi de 3,29% e no intervalo de >-7 foi de 2,71%.

E, pode-se observar que a grande parte dos genótipos se concentra com o GM 66, 68, 70, 72, 74 e, nota-se que por serem maioria, o modelo se concentrou nos intervalos de classe ade 1 a - 2,9 mostrando que conseguiu ter melhor predição nesses grupos, pois teve mais números de genótipos para alimentá-lo, e obteve um intervalo de classe de - 0,99 a 0,99 com uma porcentagem de 30,75% dos genótipos nessa classe.

Para aqueles GM com menos genótipos avaliados no caso dos GM 62, 64, 76, 78, 80 e 82 os intervalos de classe foram altos, devido menos genótipos para a comparação o modelo não conseguiu fazer a correta predição do GM tendo intervalo de classe mais alto.

Tabela 5 - Porcentagem de cada classe de acordo com a *stepwise* dos 20% retirados.

¹ GM	62	64	66	68	70	72	74	76	78	80	82	
² NG	3	8	32	75	120	122	69	29	19	33	7	PC(%)
³ IC	%											
< 7,0 /	66.67	50.00	6.25	4.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	2.13
5,0 a 6,9	33.33	0.00	12.50	4.00	1.67	0.00	0.00	0.00	0.00	0.00	0.00	1.93
3,0 a 4,9	0.00	37.50	25.00	18.67	8.33	4.10	0.00	0.00	0.00	0.00	0.00	7.74
1,0 a 2,9	0.00	12.50	43.75	42.67	34.17	23.77	14.49	6.90	0.00	0.00	0.00	24.95
-0,99 a 0,99	0.00	0.00	12.50	25.33	45.00	43.44	27.54	27.59	10.53	0.00	0.00	30.75
-1,0 a -2,9	0.00	0.00	0.00	5.33	10.00	25.41	37.68	48.28	31.58	21.21	14.29	19.54
-3,0 a -4,9	0.00	0.00	0.00	0.00	0.83	3.28	11.59	13.79	36.84	36.36	0.00	6.96
-5,0a -6,9	0.00	0.00	0.00	0.00	0.00	0.00	7.25	3.45	5.26	21.21	42.86	3.29
> -7,0	0.00	0.00	0.00	0.00	0.00	0.00	1.45	0.00	15.79	21.21	42.86	2.71

¹Grupo de maturação; ²Número de genótipos em cada grupo de maturação; ³Intervalo das classes; ⁴Porcentagem de cada classe.

Observou-se na tabela de porcentagem de cada classe pela regressão linear múltipla completa com 80% dos dados (Tabela 5) que não se nota diferenças comparando com a tabela anterior de *stepwise* (Tabela 4), grande parte dos valores nos intervalos de classes e as porcentagens de cada classe se apresentam bastante similares. Atkinson e Riani (2000) desenvolveram uma metodologia de detecção de dados considerando modelos de regressão, utilizando conjuntos de informações e dividindo em subconjuntos para ajustar a modelos com a técnica *forward*.

Neste trabalho, dividimos os 8 voos, gerando uma regressão para cada, de acordo com as refletâncias espectrais e índices de vegetação, para assim prever os grupos de maturação estimados. O modelo gerado através da regressão linear múltipla apresentou o P valor significativo, porém, com valores ainda baixos para R^2 . Com a utilização de todos os dados e com 80% dos dados apresentaram valor de R^2 de 0.37 em ambos os modelos.

Mercante et al., (2010) teve resultados semelhantes na cultura da soja, utilizando métodos de regressão linear e múltipla, em que a regressão múltipla se sobressaiu a linear, estimando índices vegetativos para avaliar as características espectrais de plantas de soja de acordo com o desenvolvimento da cultura, utilizou modelos comparando as regressões lineares múltiplas realizadas, mostrando que os resultados obtidos foram melhores do que nas regressões lineares simples, com o melhor resultado obtido de todas as análises efetuadas entre dados espectrais, para o índice GVI (índice de vegetação verde) do Landsat 5/TM (método Stepwise), o melhor resultado foi com 80,2% dos dados referenciados utilizados.

Tabela 6 - Porcentagem de cada classe pela regressão linear múltipla completa com 80% dos dados.

¹ GM	62	64	66	68	70	72	74	76	78	80	82	
² NG	3	8	32	75	120	122	69	29	19	33	7	⁴ PC(%)
³ IC	%											
< 7,0	66.67	50.00	6.25	2.67	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.93
5,0 a 6,9	33.33	0.00	18.75	5.33	1.67	0.00	0.00	0.00	0.00	0.00	0.00	2.51
3,0 a 4,9	0.00	25.00	15.63	16.00	6.67	4.92	0.00	0.00	0.00	0.00	0.00	6.38
1,0 a 2,9	0.00	25.00	46.88	46.67	39.17	21.31	13.04	6.90	0.00	0.00	0.00	26.31
-0,99 a 0,99	0.00	0.00	12.50	22.67	42.50	49.18	27.54	27.59	15.79	0.00	0.00	31.33
-1,0 a -2,9	0.00	0.00	0.00	6.67	9.17	21.31	39.13	48.28	26.32	24.24	0.00	18.57
-3,0 a -4,9	0.00	0.00	0.00	0.00	0.83	3.28	13.04	13.79	36.84	33.33	14.29	7.16
-5,0a -6,9	0.00	0.00	0.00	0.00	0.00	0.00	5.80	3.45	5.26	21.21	42.86	3.09
> -7,0	0.00	0.00	0.00	0.00	0.00	0.00	1.45	0.00	15.79	21.21	42.86	2.71

¹Grupo de maturação; ²Numero de genótipos em cada grupo de maturação; ³Intervalo das classes; ⁴Porcentagem de cada classe.

Abaixo estão os gráficos de dispersão (Figura 7 e 8), que mostram que quanto mais longe da linha estão os valores do grupo de maturação, mais dispersos os dados estão.

Foi avaliado inicialmente 2638 plantas a campo, mas após a seleção pelo método de AIC, utilizou-se o total de 517 linhagens que foram adicionadas ao modelo e o restante foi retirada como outlier, para o cálculo regressão *stepwise* obteve-se a correlação entre a avaliação do drone e a campo calculada de 0.6320 e uma regressão com R^2 de 0.3994, com 80% dos dados utilizados.

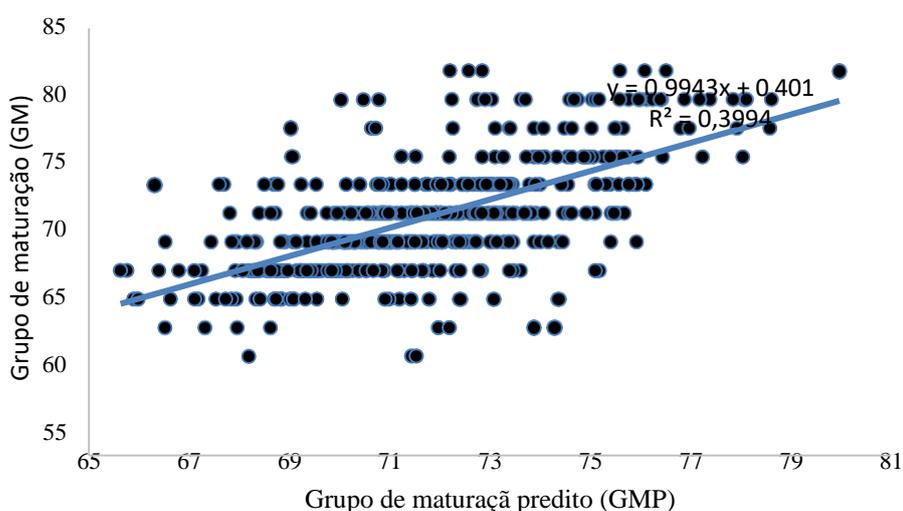


Figura 7 – Gráfico de dispersão da regressão linear simples entre o Grupo de maturação avaliado (GM) e o Grupo de maturação predito pela regressão linear múltipla *stepwise* com 80% dos dados.

No gráfico da Regressão linear simples entre o Grupo de maturação avaliado (GM) e o Grupo de maturação predito pela regressão linear múltipla completa dos 20% retirados (Figura 8) obteve-se a correlação entre a avaliação do drone e a campo calculada de 0.6311 e uma regressão com R^2 de 0.3984, com 80% dos dados utilizados.

O melhor modelo foi o modelo com a regressão de *stepwise* da Figura 7, pois teve maior porcentagem de dados passando sobre a reta (39,94%), porém a diferença entre os dois modelos é baixa.

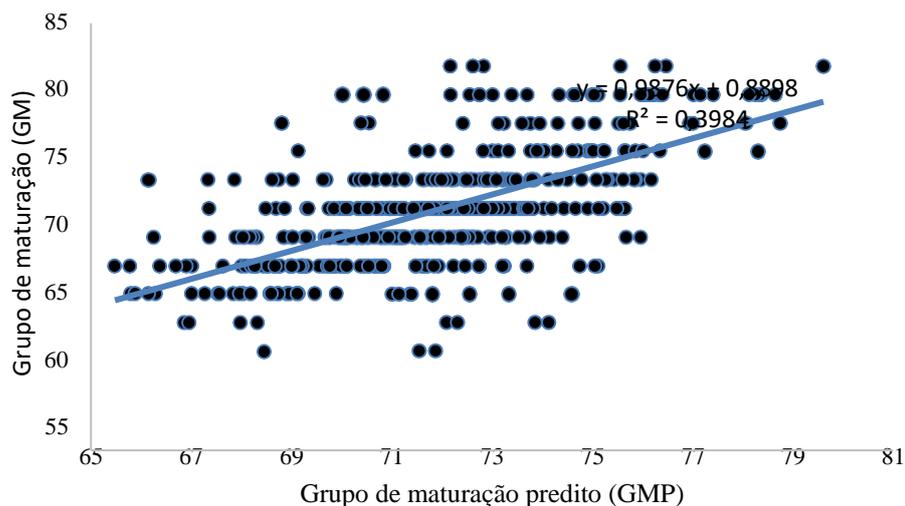


Figura 8 - Gráfico de dispersão da regressão linear simples entre o Grupo de maturação avaliado (GM) e o Grupo de maturação predito pela regressão linear múltipla completa com 80% dos dados.

Os modelos ainda precisam de ajustes, principalmente de mais variáveis para alimentá-lo e criar maior banco de dados para aumentar a capacidade de predição dos grupos de maturação na cultura da soja, pois quanto mais longe da reta da equação os dados estão, menor a precisão (Battisti, 2013), mostrando que os modelos ainda precisam de mais estudos e voos a campo para melhor predição de grupos de maturação na cultura da soja.

O trabalho mostra a importância, no caso do estudo de previsão da safra de soja, considerando o ciclo da cultura como um todo, propondo criação de métodos de avaliação de alta precisão, com a utilização de modelos estatísticos.

4. CONCLUSÃO

Conclui-se que o melhor modelo entre os avaliados foi o *stepwise*. Entretanto ainda se faz necessário a realização de mais estudos a fim de garantir maior confiabilidade no estabelecimento de modelo para a previsão os diferentes grupos de maturação em plantas de soja.

5. REFERÊNCIAS BIBLIOGRÁFICAS

Allard, R. W. Princípios do melhoramento genético das plantas. São Paulo: Edgard Blucher, 1971. 381p

Anderson, T.W. An introduction to multivariate statistical analysis. Nova York: John Wiley & Sons, 1984, 675p.

Apel, K.; Hirt, H. Reactive oxygen species: Metabolism, Oxidative Stress, and Signal Transduction. *Annual Review of Plant Biology*. 55: 373-399. 2004.

Atkinson, A. C.; Riani, M. Robust diagnostic regression analysis. New York, NY: Springer-Verlag, 2000

Battisti, R. Época de semeadura da cultura da soja com base no risco climático e na rentabilidade líquida para as principais regiões produtoras no Brasil, tese ESALQ/USP Piracicaba, 2013.

Beltrão, N. E. M.; Cardoso, G. D.; Vale, L. S. Balanço energético e “sequestro” de carbono em culturas oleaginosas. Campina Grande: Embrapa Algodão, (Embrapa Algodão. Documentos, 2007.

Bendig, J.; Yu, Kang.; Aasen, H.; Bolten, A.; Bennertz, S.; Broscheit, J.; Gnyp, M.; George, M. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, Amsterdam, NL, v.39, p.79–87, 2015.

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

Black, R. J. Complexo soja: fundamentos, situação atual e perspectiva. In: CÂMARA, G. M. S. (Ed.). Soja: tecnologia de produção II. Piracicaba: ESALQ, p.1- 18, 2000.

Brum, P.A.R.; Lima, G.J.M.M.; Ávila, V.S.; Lanznaster, M.; Ardigó, R. Características Nutricionais da Soja Desativada por Diferentes Processos Térmicos para Alimentação de Frangos de Corte. Concórdia-SC (Comunicado Técnico. Embrapa – CNPSA), 2006.

Câmara, G.M.S. Soja: tecnologia da produção II. Gil Miguel de Sousa Câmara (editor). Piracicaba: G.M.S. Câmara, 2000.

Campelo, G. J.; Kiihl, R. A. S., Almeida, L. A. Soja: Desenvolvimento para regiões de baixas latitudes. Teresina: Embrapa Meio-Norte, p. 36, 1998.

Campos, I.; Gómez, L. G.; Villodre, J.; Gonzalés-Piquera, J.; Suyker, A, E.; Calera A. Remote sensing-based crop biomass with water or light-driven crop growth models in wheat commercial fields. Field Crops Research, New jersey, USA, v.216, p.175–188, 2018.

Carvalho, N. M.; Nakagawa, j. Sementes: ciência, tecnologia e produção. 5. ed. Jaboticabal: FUNEP, 2012, 590 p

Charnet, R.; Bonvino, H; Freire C. A. L; Charnet, E. M. R. Análise de modelos de regressão linear com aplicações. Campinas, SP: Unicamp, 1999.

Clemente, T. E.; Cahoon, E. B. Soybean Oil: Genetic Approaches for Modification of Functionality and Total Content. *Plant Physiology*, v. 151, n. 3, p. 1030-1040, 2009.

Coltri, P. P.; Ramirez, G. M.; Walter, M. K C.; Junior, J. Z.; Pinto, H. S.; Nascimento. C, R.; Gonçalves, R. R. V. Utilização de índices de vegetação para estimativas não destrutivas da biomassa, estoque e sequestro de carbono do cafeeiro arábica, *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*, p. 121-128, 2009.

Conab - Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira: grãos, décimo primeiro levantamento, 2013. Disponível em: http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_06_06_09_09_27_boletim_graos. Acessado em: 02 de junho 2020

Conab - Companhia Nacional de Abastecimento. Produção de 246 milhões de toneladas garante o recorde da safra de grãos, 2019. Disponível em: <<https://www.conab.gov.br/ultimas-noticias/3140-producao-de-246-milhoes-de-toneladas-garante-o-recorde-da-safra-de-graos>> Acessado em: 2 de abril de 2020.

Conab - Companhia Nacional de Abastecimento. Produção de grãos deve superar 268 milhões de toneladas na safra 20/21, 2020. Disponível em: <https://www.conab.gov.br/ultimas-noticias/3652-producao-de-graos-deve-superar-268-milhoes-de-toneladas-na-safra-2020-21>. Acessado em: 2 de novembro de 2020.

Costa, M. M.; Mauro, A. O.; Unêda-Trevisoli, S. H.; Arriel, N. H. C.; Bárbaro, I. M.; Muniz, F. R. S. Ganho genético por diferentes critérios de seleção em populações segregantes de soja. *Pesquisa Agropecuária Brasileira*, v. 39, n. 11, p. 1095-1102, 2004.

da Silva Junior, C.A., M.R. Nanni, P.E. Teodoro, G.F.C. Silva, M.G. Lima, and M. Eri. Comparison of mapping soybean areas in Brazil through perceptron neural networks and vegetation indices. *African J. Agric. Res.* 11:114413–114424, 2016.

Embrapa – Perda e conservação dos recursos genéticos, 2009. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/656849/1/DOC221.PDF>.

Embrapa – Grupo de maturidade, 2010. Disponível em < <http://www.cnpso.embrapa.br/download/cultivares2010/LIVRETO1.pdf> > Acessado em 5 de dezembro de 2019.

Embrapa - Tecnologias de produção de soja – Região Central do Brasil 2014. - Londrina: Embrapa Soja, 2014.

Embrapa. Embrapa soja – safra brasil 2018/2019. - Embrapa soja, 2019. Disponível em: <https://www.embrapa.br/soja/cultivos/soja1> acesso em: 03/09/2019

Embrapa. Embrapa soja – Safra Brasil 2018/2019. - Embrapa Soja, 2019. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/964513/1/NDVIdeestadiosfenologicosdasojaBRS284decrecimentoindeterminadoemcasadevegetacao.pdf>. Acesso em: 09/11/2019.

Federer, W.T. Augmented designs. *Hawaiian Planter's Record* 55:191-208, 1956.

Finoto, E. L., Carrega, W. C., Sedyama, T., De Albuquerque, J. A. A., Cecon, P.R., Kong, F., Nan, H., Cao, D., Li, Y., Wu, F., Wang, J., Luab, S., Yuana, X., Coberd, L. R., Abee, J., Liu, B. A new dominant gene conditions early flowering and maturity in soybean. *Crop. Sci.* 54:2529-2535, 2014.

Fraser, C.; Ravanbakhsh, M. Georeferencing from Geoeye-1 imagery: early indications of metric performance. *Isprs Hannover Workshop, V.6*, 2009.

Gamon, J. A.; Serrano, L.; Surfus, J.S. The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels. *Oecologia*, v. 112, n.4, p. 492-501, 1997.

Gitelson, A. A.; Gritz, Y.; Merzlyak, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of plant physiology, Amsterdam*, v.160, n.3, p.271–282, 2003.

Gonzalez, R. C.; Woods, R. E. *Processamento Digital de Imagens*. São Paulo: Pearson Prentice Hall, 2010.

Hair, J. F. et al. **Análise multivariada de dados**. 5 ed. Porto Alegre: Bookman, 2005.

PEARSON, Karl. (1892), *The grammar of science*. London, J. M. Dent and Company.

Jiang, y.; wu, c.; zhang, l.; hu, p.; hou, w.; zu, w.; han, t. Long-day effects on the terminal inflorescence development of a photoperiod-sensitive soybean [Glycine max (L.) Merr.] variety. Plant Science, v.180, p.504-510, 2011.

Jensen, J.R. Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres. Tradução português 2 Ed. Parentese Editora. São José dos Campos SP, 2009.

Junior-Fonseca, E. Para a fotossíntese, luz não é qualquer luz. Revista online aquabase. São Paulo, 2018. Disponível em: <http://aquabase.com.br/wordpress/para-fotossintese-luz-nao-e-qualquer-luz/> acessado em: 15/10/2020.

Kantolic, A. G. Control ambiental y genético de la fenología del cultivo de soja: impactos sobre el rendimiento y la adaptación de genótipos. Revista da Facultad de Agronomía UBA, v.28, p.63-88, 2008.

Köppen W. Versuch einer Klassifikation der Klimate, vorzugweise nach ihren Beziehungen zur Pflanzenwelt. Geogr. Zeitschrift, 6, 657–679. KÖPPEN W., 1900: Versuch einer Klassifikation der Klimate, vorzugweise nach ihren Beziehungen zur Pflanzenwelt. Geogr. Zeitschrift, v. 6, p. 657–679, 1900.

Lira, S. A. Análise de Correlação: Abordagem Teórica e de Construção dos Coeficientes com Aplicações. Dissertação ao Curso de Pós Graduação em Métodos Numéricos em Engenharia- UFPR, 2004.

Longhitano, G. A. “Vants para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas”. 148 p., Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo - Departamento de Engenharia de Transportes, São Paulo, 2010.

Martins, C.C.; Unêda-Trevisoli, S. H.; Môro, G. V.; Vieira, R, V. Metodologia para seleção de linhagens de soja visando germinação, vigor e emergência em campo Revista Ciência Agronômica, v. 47, n. 3, p. 455-461, 2016.

Mapa - Ministério da Agricultura Pecuária e Abastecimento, Projeções do agronegócio, 2017. Disponível em: <http://www.agricultura.gov.br/assuntos/politica-agricola/todas-publicacoes-////de-politica-agricola/projecoes-do-agronegocio/projecoes-do-agronegocio-2017-a-2027-versao-preliminar-25-07-17.pdf>. Acessado em: 02 de setembro de 2019

Mazoyer, M.; Roudart, L. História das agriculturas no mundo. São Paulo: Editora UNESP, 2008.

Menezes, P.R.; Almeida, T. Introdução ao Processamento de Imagens de Sensoriamento Remoto, 2012. Disponível em: <https://blog.droneng.com.br/o-que-e-sensoriamento-remoto/>

Meotti, G.V., Benin, G., Silva, R.R., Beche, E., Munaro, L.B. Épocas de semeadura e desempenho agrônômico de cultivares de soja. Pesq. Agropec. Bras. 47:14-21, 2012.

Mercante, E, Lamparelli, R.A.C, Uribe-Opazo, M.A., Rocha, J.V. Características espectrais da soja ao longo do ciclo vegetativo com imagens Landsat 5/TM área agrícola no oeste do Paraná. Eng. Agríc. 29:328-338, 2010.

Miranda, D. L. C. De; Melo, A. C. G. De; Sanquetta, C. R. Equações alométricas para estimativa de biomassa e carbono em árvores de reflorestamentos de restauração. *Revista Árvore*, Viçosa, MG, v. 35, n. 3, Edição Especial, p. 679-689, 2011.

Moeckel, T.; Safari, H.; Reddersen, B.; Fricke, T.; Wachendorf, M. Fusion of ultrasonic and spectral sensor data for improving the estimation of biomass in grasslands with heterogeneous sward structure. *Remote Sensing*, Basel, Switzerland, v.9, n.1, p.98, 2017.

Mukaka, M. M. A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, [S.l.], v.24, n.3, p.69–71, 2012.

Oliveira – seco, M. A. Comportamento espectral de plantas como ferramenta de determinação metodológica para monitoramento de espécies invasoras, Maringá, 2014.

Pelúzio, J. M.; Fidelis, R. R.; Junior Almeida, D.; Santos, G. R.; Didonet, J. Comportamento de cultivares de soja no Sul do Estado do Tocantins. *Bioscience Journal*, v. 01, n. 03, p. 113-117, 2005.

Rahman, A. Gamon, J.A.; Fuentes, D.A.; Roberts, D.A.; Prentiss, D. Modeling distributed ecosystem flux of boreal forest using hyperspectral indices from AVIRIS imagery. *Journal of Geophysical Research*, v. 106, n.24, p. 579-591, 2001.

Sedyama, T.; Teixeira, R. C.; Reis, M. S. Melhoramento de soja. In: BOREM, A. (Ed.). *Melhoramento de espécies cultivadas*. Viçosa (MG): Ed. da UFV, 2013. p. 553-603.

Setzer, J. Atlas Climático e Ecológico do Estado de São Paulo. Ed. Comissão Interestadual da Bacia do Paraná-Uruguaí em colaboração com as centrais elétricas de SP. (CESP). São Paulo. p 35-39, 1996.

Silva, J. B. Caracterização química, físico-química e sensorial de extrato de soja em pó. Dissertação (Mestrado em Ciência de Alimentos) Universidade Estadual de Londrina, Londrina, 2005.

Silva, F.C.S., Sedyama, T., Oliveira, R.C.T., Borém, A., Silva, F.L., Bezerra, A.R.G., Silva, A.F. Importância econômica e evolução do melhoramento. In: Silva, F.L., Borém, A., Sedyama, T., Ludke, W. (Eds). Melhoramento da Soja. UFV, Viçosa, 2017.

Sinclair, T. R., Neumaier, N., Farias, J. R. B., & Nepomuceno, A. L. (2005). Comparison of vegetative development in soybean cultivars for low latitude environments. *Field Crops Research*, v. 92, p. 53-59, 2005.

Teixeira, F. G. Herança da precocidade e de caracteres agronômicos em soja e seleção de linhagens com base em índices de seleção. Dissertação (Mestrado em Agronomia), Universidade Federal de Uberlândia, 2017.

Torres, F.E.; Silva, E.C. e Teodoro, P.E. (2014) - Desempenho de genótipos de soja nas condições edafoclimáticas do ecótono Cerrado-Pantanal. *Interações*, v. 15, n. 1, p. 71-78.

Upton, G.; Fingleton, B. *Spatial Data Analysis by Example*, volume I – Point pattern and quantitative data, Chichester: John Wiley & Sons, 1985.

Vasconcelos, E. S. et al. Estimativas de parâmetros genéticos da qualidade fisiológica de sementes de genótipos de soja produzidas em diferentes regiões de Minas Gerais. *Semina: Ciências Agrárias*, v. 33, n. 1, p. 65-76, 2012.

Watanabe, S., Harada, K., Abe, J. Genetic and molecular bases of photoperiod responses on flowering in soybean. *Breed. Science*, n 61 p. 531-543, 2012.

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*, v171–172, p. 281-294, 2013.

Zhang, C.; Kovacs, J. M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, v. 13, n. 6, p. 693-712, jul. 2012. Disponível em: < <http://link.springer.com/article/10.1007%2Fs11119-012-9274-5> >. Acesso em: 03 maio 2015.