

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA

GOIANO CAMPUS RIO VERDE-GO

DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO

PROGRAMA DE PÓS GRADUAÇÃO EM BIOENERGIA E GRÃOS

DETERMINAÇÃO DE GRUPO DE MATURAÇÃO DE SOJA *Glycine max* L. Merrill

ATRAVÉS DO USO DE IMAGENS RGB CAPTURADAS POR VANT

Autor: Rogério Silva Ferreira

Orientador: Professor Dr. Pablo Diego Silva Cabral

Co-orientador: Professor Dr. Leonardo Garcia Marques

Rio Verde – GO

Agosto – 2021

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA

GOIANO CAMPUS RIO VERDE-GO

DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO

PROGRAMA DE PÓS GRADUAÇÃO EM BIOENERGIA E GRÃOS

DETERMINAÇÃO DE GRUPO DE MATURAÇÃO DE SOJA *Glycine max* L. Merrill
ATRAVÉS DO USO DE IMAGENS RGB CAPTURADAS POR VANT

Autor: Rogério Silva Ferreira

Orientador: Professor Dr. Pablo Diego Silva Cabral

Co-orientador: Professor Dr. Leonardo Garcia Marques

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

Agosto – 2021

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

F383d Ferreira, Rogerio Silva
 DETERMINAÇÃO DE GRUPO DE MATURAÇÃO DE SOJA
Glycine max L. Merrill ATRAVÉS DO USO DE IMAGENS RGB
CAPTURADAS POR VANT / Rogerio Silva Ferreira;
orientador Pablo Diego Silva Cabral; co-orientador
Leonardo Garcia Marques. -- Rio Verde, 2021.
 39 p.

Dissertação (Mestrado em Pós Graduação em Bioenergia
e Grãos) -- Instituto Federal Goiano, Campus Rio
Verde, 2021.

1. Regressão Múltipla. 2. Modelo Misto. 3.
Fenotipagem. 4. Maturação Relativa da Soja. 5. Drone.
I. Cabral, Pablo Diego Silva , orient. II. Marques,
Leonardo Garcia, co-orient. III. 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: Rogério Silva Ferreira

Matrícula: 2019202331540043

Título do Trabalho: DETERMINAÇÃO DE GRUPO DE MATURAÇÃO DE SOJA Glycine max L. Merrill ATRAVÉS DO USO DE IMAGENS RGB CAPTURADAS POR VANT

Restrições de Acesso ao Documento

Documento confidencial: Não Sim, justifique: Será submetido a solicitação de patente

Informe a data que poderá ser disponibilizado no RIIF Goiano: __/__/__

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, 04/08/2021.
Local Data

Assinatura do Autor e/ou Detentor dos Direitos Autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)



Ata nº 61/2021 - NREPG-RV/CPG-RV/DPGPI-RV/CMPRV/IFGOIANO

PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
ATA Nº 39 (TRINTA E NOVE)
BANCA EXAMINADORA DE DEFESA DE DISSERTAÇÃO

Aos vinte e nove dias do mês de junho do ano de dois mil e vinte e um, às 08h00min (oito horas), reuniram-se os componentes da banca examinadora em sessão pública realizada por videoconferência, para procederem a avaliação da defesa de Dissertação, em nível de mestrado, de autoria de **ROGÉRIO SILVA FERREIRA**, discente do Programa de Pós-Graduação em Bioenergia e Grãos do Instituto Federal Goiano - Campus Rio Verde. A sessão foi aberta pelo presidente da Banca Examinadora, Prof. Dr. Pablo Diego da Silva Cabral, que fez a apresentação formal dos membros da Banca. A palavra, a seguir, foi concedida ao autor da Dissertação que, em 30 min., procedeu à apresentação de seu trabalho. Terminada a apresentação, cada membro da banca arguiu o examinado, tendo-se adotado o sistema de diálogo sequencial. Terminada a fase de arguição, procedeu-se a avaliação da defesa. Tendo-se em vista as normas que regulamentam o Programa de Pós-Graduação em Bioenergia e Grãos, e procedida às correções recomendadas, a Dissertação foi APROVADA, considerando-se integralmente cumprido este requisito para fins de obtenção do título de **MESTRE EM BIOENERGIA E GRÃOS**, na área de concentração Agroenergia, pelo Instituto Federal Goiano - Campus Rio Verde. A conclusão do curso dar-se-á quando da entrega na secretaria do PPGBG da versão definitiva da Dissertação, com as devidas correções. Assim sendo, a defesa perderá a validade, se não cumprida essa condição, em até **60 (sessenta) dias** da sua ocorrência. A Banca Examinadora recomendou a publicação dos artigos científicos oriundos dessa Dissertação em periódicos de circulação nacional e/ou internacional, após procedida as modificações sugeridas. Cumpridas as formalidades da pauta, a presidência da mesa encerrou esta sessão de defesa de Dissertação de Mestrado, e para constar, foi lavrada a presente Ata, que, após lida e achada conforme, será assinada eletronicamente pelos membros da Banca Examinadora.

Membros da Banca Examinadora

Nome	Instituição	Situação no Programa
Pablo Diego da Silva Cabral	IF Goiano - Polo de Inovação	Presidente
Tavvs Micael Alves	IF Goiano - Polo de Inovação	Membro interno
Leonardo Garcia Marques	IF Goiás - Campus Itumbiara	Membro externo

Documento assinado eletronicamente por:

- Leonardo Garcia Marques, Leonardo Garcia Marques - Professor Avaliador de Banca - Instituto Federal Goiano - Campus Rio Verde (30653437000500), em 12/06/2021 09:33:43.
- Tavvs Micael Alves, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 02/07/2021 15:58:24.
- Pablo Diego Silva Cabral, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 29/06/2021 14:29:30.

Este documento foi emitido pelo SUAP em 27/06/2021. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <http://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 281589
Código de Autenticação: 30c0ec696b



DEDICATÓRIA

Dedico esta obra a minha esposa Roberta Hayane Pains e meus filhos Gustavo Pains Ferreira e Theo Pains Ferreira, por todo apoio durante a caminhada.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me dado saúde, disposição e a oportunidade de galgar mais este degrau na escada do conhecimento. Agradeço a minha esposa Roberta e meus filhos Gustavo e Théó, por estarem ao meu lado dando força em todos os momentos. Agradeço a empresa Corteva Agriscience que permitiu que eu dedicasse parte do meu tempo na realização deste tão sonhado projeto acadêmico. Agradeço aos meus colegas de curso que sempre que necessário estiveram prontos para colaborar. Agradeço ao meu orientador e professor Dr. Pablo Cabral, pelos conhecimentos transmitidos e pelo apoio desde o início do programa, na pessoa da qual eu estendo o meu agradecimento ao Instituto Federal Goiano – IFG campus Rio Verde e a todos os seus colaboradores.

SUMÁRIO

1.INTRODUÇÃO	3
2.REVISÃO BIBLIOGRÁFICA	6
2.1 Soja ao Longo da História.....	6
2.2 Os diversos Usos da Soja	7
2.3 Botânica da Soja.....	8
2.4 Grupo de Maturação Relativa da Soja	9
2.5 Sensoriamento Remoto	12
2.5.1 As Cores	13
2.5.2 – Índices de Vegetação.....	14
2.5.3 Representação de Cores RGB	15
2.5.4 A Coloração das Plantas e a Clorofila.....	16
3.MATERIAL E MÉTODOS	18
4.RESULTADOS E DISCUSSÃO.....	23
5.CONCLUSÃO	32
6. CONSIDERAÇÕES FINAIS	34
6.REFERÊNCIAS BIBLIOGRÁFICAS	35

**DETERMINAÇÃO DE GRUPO DE MATURAÇÃO DE SOJA *Glycine max* L.
Merril ATRAVÉS DO USO DE IMAGENS RGB CAPTURADAS POR VANT**

por

ROGÉRIO SILVA FERREIRA

Sob Orientação do Professor Dr. Pablo Diego Cabral – IFG Rio Verde GO

Resumo: A probabilidade de se desenvolver cultivares de soja mais produtivas está diretamente relacionada com a capacidade de fenotipagem que é um fator limitante no processo de melhoramento, pois, grande número de linhagens precisa ser avaliado para que seja possível selecionar uma população superior. A caracterização da maturação relativa de cultivares é uma das várias características que precisam ser avaliadas no processo de fenotipagem. Atualmente, esta atividade é feita de forma manual, demandando grande quantidade de tempo dos pesquisadores. Os veículos aéreos não tripulados (VANTs), também conhecidos como drones são formas rápidas e baratas de se obter imagens de lavoura. Esta pesquisa teve como objetivo fazer a predição de maturação relativa de soja com base na soma térmica acumulada, imagens RGB capturadas por drone e o índice VARI. Utilizando regressão múltipla em Python foi possível prever a maturação relativa com um R^2 de 0.92, já com um modelo linear misto em R, foi possível prever a maturação relativa de cultivares com um R^2 de 0.996.

PALAVRAS-CHAVE: Regressão Múltipla, Modelo Misto, Fenotipagem, Maturação Relativa da Soja, Predição, Drone.

**DETERMINAÇÃO DE GRUPO DE MATURAÇÃO DE SOJA *Glycine max* L.
Merril ATRAVÉS DO USO DE IMAGENS RGB CAPTURADAS POR DRONE**

por

ROGÉRIO SILVA FERREIRA

Sob Orientação do Professor Dr. Pablo Diego Cabral – IFG Rio Verde GO

Abstract: The probability of developing more productive soybean cultivars is directly related to the phenotyping capacity which is a limiting factor in the breeding process, since many lines need to be evaluated to select a superior population. The cultivars characterization of relative maturity is one of several characteristics that need to be evaluated in the phenotyping process. This activity is done manually, which requires a large amount of time from researchers. Unmanned aerial vehicles (UAVs), also known as drones, are a quick and inexpensive way to obtain crop images. This research aimed to predict the relative maturity of soybean based on accumulated heat units, RGB images captured by drone and the VARI index. Using multiple regression in Python, it was possible to predict the relative maturity with an R^2 of 0.92, whereas with a mixed linear model in R, it was possible to predict it with an R^2 of 0.996.

KEY WORDS: Multiple Regression, Mixed Model, Phenotyping, Soybean Relative Maturity, Prediction, Drone.

1.INTRODUÇÃO

O crescente aumento da população mundial ao longo dos últimos anos e a necessidade da produção de combustíveis à base de fontes renováveis colocam em evidência a importância da agricultura para as próximas gerações (Ray et al., 2013). Para atender a demanda de comida necessária para alimentar a população mundial projetada para 2050, será preciso aumentar a produção agrícola em 60 a 110% em relação ao que é produzido na atualidade (Ray et al., 2013). Para atender esta demanda, será necessário aumento de produtividade média anual de 2,4% nas principais culturas provedoras de carboidrato e proteína, porém as análises mostram que há ganhos médios entre 0,6 a 1,6% ano, e não são suficientes para atender a necessidade estimada. Não se vislumbra outras opções para aumentar a produção de alimentos no mundo a não ser aumentando as áreas agrícolas ou melhorando a eficiência da produção (Tilman et al., 2011). A abertura de novas áreas implica em destruir florestas, atividade esta que tem sido amplamente questionada em função de impactos ambientais (Rivero et al., 2009), restando então a melhoria da eficiência na produtividade como a alternativa ambientalmente viável em médio e longo prazo (Ray et al., 2013).

A melhoria da produtividade pode ser alcançada com a aplicação de técnicas de manejo que objetivam o maior rendimento possível dos materiais genéticos existentes e com a pesquisa em melhoramento genético que visa desenvolver materiais superiores aos existentes no mercado. Em se tratando de melhoramento genético, se manter os ganhos genéticos que se têm ao longo da história, não será possível suprir a demanda de alimentos prevista para 2050 (Huihui et al., 2018).

Uma das formas de aumentar o ganho genético será acelerar o processo de melhoramento, porém, isso encontra limitação em função dos longos períodos de ciclo das culturas cultivadas

para alimentação humana (Watson, 2018). A fenotipagem de plantas se baseia em três princípios básicos: genótipo, ambiente e a interação entre genótipo e ambiente (Sadras et al., 2013). Se considerar que ao longo do cultivo há o mesmo genótipo, pode-se assumir que o que irá fazer a diferença no final é a interação entre genótipo ambiente, que pode ser avaliada em diferentes momentos do desenvolvimento da cultura. Se fosse possível prever com antecedência algumas características, como por exemplo a produtividade, não seria necessário aguardar até o final do ciclo para selecionar os melhores materiais dentro de uma população (Yuan et al., 2019).

Pesquisas foram capazes de prever características agronômicas de algumas espécies, como por exemplo: predição de rendimento de soja usando índice vegetativo normalizado no período reprodutivo (Ma et al., 2001), predição do teor de nitrogênio em amêndoas no verão, usando o teor de nitrogênio e boro no inverno (Saa et al., 2014), predição da produtividade de videiras com base no número de cachos em estágio de desenvolvimento inicial (Aquino et al., 2018).

Uma ferramenta adequada para auxiliar a fenotipagem, precisa ser aplicável em larga escala, eficiente e não destruir o material analisado, pois em muitos casos, as parcelas estudadas precisam ser preservadas para propagações futuras (Yuan et al., 2019). Neste contexto, o uso de imagens para realização de predições parece ser uma solução promissora. Imagens multispectrais podem fornecer dados sobre as plantas que são impossíveis de se detectar a olho nu, porém, no momento, os dispositivos que fazem este tipo de imagem são caros e complexos. Já as câmeras RGB (Vermelho, Verde e Azul) são baratas, fáceis de operar, podem ser facilmente acessadas por usuários comuns, inclusive acopladas a smartphones e por isso parecem ser uma ótima alternativa para a fenotipagem automática, bastando apenas que se desenvolvam modelos que sejam capazes de extrair as informações deste tipo de imagem (Yuan et al., 2019).

A cor é uma característica percebida pela vista humana e tem grande relação com a fisiologia da planta. Pode ser usada por exemplo para fazer segmentação do vegetal (Hamuda et al., 2016), avaliação de estresse da planta (Bai et al., 2018), detecção de manchas de doenças e volume de biomassa (Chaudhary et al., 2012).

A classificação do grupo de maturação da soja, está relacionado com a quantidade de dias que uma cultivar demora para atingir a maturação fisiológica, ou seja, 95% de plantas de uma população com aspecto de madura. No Brasil, a classificação é feita com numeração que varia de 4 a 9, sendo o grupo 4 o mais precoce e o 9 o mais tardio (Gomes et al., 2016). Este modelo foi estudado por Alliprandini *et al.*, (2009) com base em modelos usados nos Estados Unidos e a cada ano que se passa novos estudos são necessários, pois novas cultivares são lançadas no mercado e a cultura é introduzida em novos ambientes agrícolas.

Uma tecnologia que tem se mostrado muito útil para a agricultura são os chamados veículos aéreos não tripulados (VANT's), também conhecidos como drones. Estes equipamentos permitem a obtenção de imagens aéreas de grandes áreas com um custo operacional relativamente baixo. Estes equipamentos são equipados com câmeras que podem obter imagens em altas resoluções, com precisão de centímetros e podem ser usadas em larga escala (Franchini et al., 2018). As vantagens da capacidade amostral dos VANT's associado com técnicas de análise de imagens tem sido objeto de estudo para desenvolver metodologias que possibilitem ampliar a capacidade de fenotipagem. Em pesquisas, Yuan et al., (2019) foi capaz de obter diversas predições para a cultura da soja usando imagens capturadas por VANT's ao longo do ciclo da cultura.

Nesse sentido, o objetivo deste trabalho foi desenvolver uma metodologia para predição do grupo de maturação de soja com base em imagens RGB capturadas por VANT, associado ao acúmulo térmico utilizando ferramentas estatísticas.

2.REVISÃO BIBLIOGRÁFICA

2.1 Soja ao Longo da História

A soja (*Glycine max* L. Merrill) talvez seja um dos primeiros cereais cultivados pelo homem com o propósito de produção de alimento (Bonato & Bonato, 1987). Há relatos de recomendação de cultivo de soja datados de 2.207 anos A.C. Nestes registros foi possível encontrar diretrizes de métodos de plantio, variedades, épocas de colheita e armazenamento (Morse, 1950). Alguns consideram o local de origem a região central da China (Morge, 1950) já outros acreditam que o cereal começou a ser cultivado, inicialmente na parte norte deste país (Hymowitz,1970). Apesar de haver discordância sobre a exata região de origem, a maioria dos pesquisadores concordam que os chineses foram o primeiro povo a cultivar a oleaginosa.

Fora do continente Asiático, há relatos que em 1712, um botânico alemão por nome de Engelbert Kaempher fez demonstrações aos europeus sobre o uso da soja como alimento, com base em experiências tidas no Japão durante os anos de 1691 e 1692. O primeiro plantio experimental em terras europeias só ocorreu no ano de 1739, quando o jardim botânico de Paris recebeu um lote de sementes provenientes da China, levados por missionários. Já em 1790, foi a vez dos ingleses iniciarem o cultivo no jardim botânico real, em Kew (Piper & Morse, 1923).

Já na América do Norte, o primeiro relato de cultivo de soja foi em 1804, no estado da Pensilvânia, nos Estados Unidos da América, conforme descrito por (Piper & Morse, 1923), demorou quase oitenta anos para que a cultura passasse a interessar os agricultores deste país. Já na América do Sul, a cultura foi introduzida primeiramente no Brasil, no ano de 1882 no estado da Bahia por Gustavo D'utra (Dutra, 1882). Dez anos depois Daffert (Daffert , 1892) cita os primeiros estudos com soja no estado de São Paulo, especificamente na Estação Agronômica de Campinas, hoje conhecido como Instituto Agronômico de Campinas. Devido as excelentes

condições agrícolas do Brasil a soja rapidamente se expandiu para região sul do país que possui um clima mais parecido com a região sul dos Estados Unidos, de onde vieram as primeiras cultivares trazidas para o Brasil (Bonato, 1987). À partir da década de 1970, começa a migração da cultura da soja para região Centro-Oeste, Norte e Nordeste e novamente a cultura encontra abundância de áreas e clima favorável para cultivo (Bonato, 1987).

Desde então, a soja tem se destacado como uma das principais culturas agrícolas, ultrapassando a marca de 330 milhões de toneladas produzidas em uma área superior a 120 milhões de hectares em todo o mundo. No Brasil a importância ainda é mais significativa, sendo que na safra 2019/2020 a área plantada superou 36 milhões de hectares, levando o Brasil a ser o maior plantador de soja, sendo responsável por 30% de toda a produção mundial (USDA, 2020).

2.2 Os diversos Usos da Soja

A popularidade da soja, se deve a sua grande capacidade em fornecer proteína com custo relativamente barato. Uma porção de 1 kg soja pode conter aproximadamente a mesma quantidade de proteína que 2 kg de carne bovina ou 3 kg de feijão (Sindimilho & Soja, 2020). Pesquisadores têm obtido resultados que demonstram benefícios do consumo de produtos à base de soja na prevenção de doenças cardiovasculares, osteoporose e alguns tipos de câncer, além de ser uma dieta que auxilia no processo de ganho de massa magra em humanos (Esteves & Monteiro, 2001). Mesmo com a comprovação dos benefícios nutricionais e funcionais da soja na alimentação humana, o seu uso direto ainda é relativamente baixo. Isso pode estar relacionado ao sabor e ao odor desagradáveis causado por diversos compostos que estão presentes no grão, fazendo com que o cereal seja utilizado em sua maioria para alimentação animal (Morais & Silva, 2000). Já os subprodutos derivados de soja são amplamente utilizados na indústria alimentícia, principalmente aqueles à base de cereais e de carnes. A soja proporciona a estes

alimentos uma composição menos calórica, com reduzido teor de lipídeos e adequado conteúdo de proteína.

Os subprodutos de soja estão presentes em inúmeros produtos que se consome atualmente, na alimentação humana, tem-se por exemplo o óleo e a gordura vegetal com suas diversas aplicabilidades. Na indústria de cosméticos são usados como componentes de produtos de beleza. Na produção de combustível, como parte do biodiesel e são amplamente usados na produção de rações para alimentação animal (Aprosoja, 2020).

2.3 Botânica da Soja

Planta *Glycine max* (L) Merrill que é comumente conhecida na língua Portuguesa como soja ou no inglês como soybeans, é uma planta herbácea pertencente a classe *Rosidae*, ordem *Fabales*, família *Fabacea*, subfamília *Papilionoideae*, tribo *Phaseoleae*, gênero *Glycine* L., espécie *max*. Dentre as cultivares comerciais predomina a presença de caule híspido com pouca ramificação. O sistema radicular é formado por um eixo principal com ramificações laterais, também conhecido como sistema radicular pivotante. Ao germinar a planta emite primeiro os cotilédones, em seguida um par de folhas opostas e posteriormente as folhas emitidas serão agrupadas três a três, o que é chamado de trifólio. A emissão dos trifólios é feita de forma alternada ao longo do caule. As estruturas reprodutivas masculinas e femininas estão presentes na mesma flor, e faz com que a planta tenha fecundação predominantemente do tipo autógama, ou seja, autofecundação. Quanto a cor, as flores podem ser brancas, roxas ou de coloração intermediária. A planta desenvolve vagens, inicialmente com coloração verde e à medida que estas amadurecem tem sua coloração alterada, variando de amarelo-pálido até diferentes tons de marrom ou cinza. As vagens desenvolvem geralmente de uma a cinco sementes. As sementes são lisas, com formato redondo ou elíptico, com tegumento amarelo pálido, com hilo preto, marrom ou amarelo-palha.

Quanto ao crescimento a soja pode apresentar hábito determinado, com a presença de racemo terminal, indeterminado, sem a presença do racemo terminal e, também o hábito semideterminado, com características intermediárias a hábitos determinado e indeterminado. A estatura da planta de soja está diretamente relacionada às condições ambientais e a cultivar plantada. Atualmente, o mercado tem preferido cultivares com altura variando de 60 a 110 cm, pois estas são medidas que possibilitam adequada colheita mecanizada e não causam acamamento, que pode ocorrer na medida em que a planta de soja cresce exacerbadamente (Embrapa, 2020).

A emissão de flores da soja também é influenciada pelo ambiente, mais especificamente pela quantidade de horas com luz no dia, também conhecido como fotoperíodo. A soja tem seu florescimento induzido em épocas do ano com dias curtos, ou seja, menos horas de luz. Já quando cultivadas em dias longos estas têm seu florescimento atrasado, conseqüentemente alongando o ciclo. Ao longo do processo de melhoramento da soja, pesquisadores selecionaram genótipos que apresentam florescimento tardio mesmo em épocas de dias curtos, esta característica ficou conhecida como período juvenil. Este fato acabou se tornando uma ferramenta importante no processo de melhoramento da soja no Brasil, possibilitando o desenvolvimento de cultivares adaptadas a todas as regiões agrícolas do país, até mesmo próximo a linha do equador. Este feito rendeu ao Brasil o título de país que mais “tropicalizou” a soja (EMBRAPA, 2020).

2.4 Grupo de Maturação Relativa da Soja

A classificação do grupo de maturação da soja está relacionada com a quantidade de dias que uma cultivar demora para atingir a maturação fisiológica, ou seja, 95% de plantas de uma população com aspecto de madura. No Brasil, a classificação é feita com numeração que varia de 4.0 a 9.0, sendo o grupo 4.0 o mais precoce e o grupo 9.0, o mais tardio. A variação na escala

de maturação relativa é da ordem de 0.1 (Gomes et al., 2016). Este modelo foi desenvolvido nos Estados Unidos e foi estudado no Brasil por Alliprandini et al., (2009).

De acordo com os estudos realizados por Alliprandini et al., (2009), cada variação de 0.1 no grupo de maturação relativa da soja equivale aproximadamente 15,5 dias, podendo haver pequenas alterações em função de clima, altitude e posição geográfica que uma cultivar é plantada.

Durante a fase de desenvolvimento, as cultivares são testadas em algumas regiões chave e depois de lançadas, elas podem ser amplamente utilizadas nas mais diversas regiões do país. As variações climáticas e geográficas podem levar a uma inconsistência entre o grupo de maturação definido pelo desenvolvedor e o comportamento do material em uma determinada situação e região de cultivo. Em pesquisas realizadas a nível de campo, foi possível identificar diferenças de até 0.6 quando comparado o grupo de maturação expressado pela cultivar em uma condição e o grupo de maturação definido para a cultivar pelo desenvolvedor (Gomes et al., 2016), ou seja, transformando em dias, têm-se uma diferença superior a 9 dias de ciclo entre o especificado e o que realmente ocorreu na prática.

Dos fatores ambientais que podem interferir no ciclo de florescimento e maturação da soja, certamente a temperatura, o fotoperíodo e a disponibilidade hídrica são os mais determinantes. A temperatura está relacionada com a altitude e a posição geográfica da área. Os locais mais altos, de uma forma geral tendem a ter temperaturas médias mais baixas e isso favorece um desenvolvimento mais lento da soja. Já, nas regiões baixas ocorre o inverso, as temperaturas médias maiores tendem a fazer com que o ciclo de soja se encurte (Bergamaschi, 2014).

Com relação a disponibilidade hídrica, as secas podem diminuir a taxa de acúmulo de matéria seca nos grãos afetando o rendimento e apressando a maturação, encurtando o ciclo da soja. (Embrapa, 2007)

O fotoperíodo está relacionado com a duração do ciclo luminoso. A soja é uma planta considerada de dia curto, pois tem o seu florescimento induzido nesta condição ambiental, ou seja, fora do período juvenil, uma planta de soja será induzida a florescer caso tenha uma quantidade de horas de luz no dia inferior a um certo valor (Bergamaschi, 2014).

Dentre os vários fatores ambientais envolvidos no desenvolvimento da soja, a temperatura média durante o ciclo é sem dúvida um dos mais importantes. Pesquisadores ao longo da história buscaram vários métodos para relacionar o grau de desenvolvimento de uma cultura com a temperatura média do ar. Dentre estes métodos, um dos mais utilizados é o método das unidades térmicas, também conhecido com GDU, do inglês “Grow Degree Unit”. Este método se baseia na premissa de que uma planta necessita de uma certa quantidade de energia, representada pela soma de graus térmicos acima de uma temperatura base para completar determinada fase fenológica, ou mesmo todo seu ciclo (Camargo et al., 1987).

Cada espécie vegetal possui uma temperatura base e há variação até mesmo entre variedades dentro de uma mesma espécie. A temperatura base também pode variar em função da idade da planta, porém em termos práticos, é comum considerar uma mesma temperatura base para todo o ciclo da uma cultura e admitir uma relação linear entre o acúmulo térmico e o desenvolvimento vegetal, respeitando limites máximos e mínimos nos quais teoricamente uma planta cessa o seu desenvolvimento (Camargo et al. 1987).

A temperatura base de desenvolvimento da soja pode ter algumas variações entre cultivares, porém, estudos realizados, indicaram que 14°C é uma temperatura que pode ser aplicada de forma genérica para as condições brasileiras. Para se calcular a quantidade diária de calor acumulada, basta calcular a temperatura média do dia e subtrair pela temperatura base 14°C (Camargo et al. 1987).

Para a soja, o método de somas térmicas, geralmente não apresenta bons resultados, pois o fator fotoperíodo também tem grande influência no desenvolvimento da mesma, sendo que

diferenças de duração de ciclo de uma mesma cultivar plantada na mesma data ao longo de vários anos, está relacionado com a variação de temperatura, já a diferença entre cultivares está relacionado com o fotoperíodo (Miyasaka & Medina, 1981).

De posse da temperatura base, é possível calcular a soma térmica acumulada desde o plantio até determinado momento do ciclo da cultura, como por exemplo o início do florescimento. Uma cultivar de soja precoce precisa acumular em média 1030 unidades de calor para atingir a maturação (Camargo et al. 1987).

2.5 Sensoriamento Remoto

O termo “sensoriamento remoto” se refere a obtenção de imagens de forma remota da superfície de um alvo, com o uso sensores embarcados em aeronaves ou satélites. Este pode ser usado para o monitoramento de plantas e conseqüentemente aplicado na agricultura (Dornhofer & Oppelt, 2016). O sensoriamento remoto se baseia na espectroscopia da radiação refletida por uma superfície na qual incide radiação solar. A radiação emitida e refletida se divide em diferentes comprimentos de ondas, sendo a região do visível de 0,4 μm a 0,7 μm , infravermelho próximo 0,7 μm a 1,3 μm e infravermelho de ondas curtas 1,3 μm a 2,5 μm (Jorge & Inamasu, 2014).

Imagens capturadas por satélites podem ter grande utilidade na agricultura, todavia possui algumas limitações relacionadas com frequência de visita do satélite, presença de nuvens, elevado custo de processamento e pouca resolução espacial, dificultando a análise detalhada de uma área específica (Samseemoung et al., 2012). Por outro lado, os veículos aéreos não tripulados (VANTs), popularmente conhecidos como drones, permitem a captura de imagens aéreas de grandes áreas com baixo custo, grande frequência e com alta resolução, complementando, assim as lacunas deixadas pela aplicação das imagens de satélite (Jorge & Inamasu, 2014).

2.5.1 As Cores

A percepção das diferentes tonalidades de cores que se enxerga se dá, basicamente, por meio de dois fenômenos distintos cuja origem pode ser química ou física. A cor química tem como base o princípio de absorção e reflexão, enquanto a cor física (ou estrutural) se baseia no princípio de redirecionamento da luz por um corpo. Ambas são comumente observadas na natureza e dão a alguns organismos colorações impressionantes, que em muitos casos podem estar relacionadas com a camuflagem. Cada faixa de cor tem um comprimento de onda específico, sendo que o olho humano em condições normais é capaz de captar apenas uma pequena faixa do espectro eletromagnético, que é o que é chamado de luz visível, que varia de comprimentos de onda que vão de 450 nm até 700 nm, como mostrado na figura 1.




Fig 1: Representação do espectro da luz
<https://brasilecola.uol.com.br/fisica/espectro-eletromagnetico.htm>

Atualmente, existem sensores que são capazes capturar desde os comprimentos de onda na faixa da luz visível, até mesmo faixas muito abaixo ou muito acima deste limite. Os sensores mais simples que trabalham na faixa da luz visível geralmente tem preço mais acessível quando comparados aos sensores multiespectrais e hiperspectrais. Esses sensores permitem uma caracterização muito mais detalhada, pois são capazes de capturar maior amplitude de comprimentos de ondas (Furlanetto et al., 2017).

2.5.2 – Índices de Vegetação

Os índices de vegetação obtidos através de imagens aéreas são rápidos, econômicos e confiáveis para o acompanhamento de culturas (Candiago et al., 2015), com vantagem sobre outras técnicas de avaliação, que é a não necessidade de coletar ou destruir tecidos para obtenção de parâmetros, pois a coleta das imagens é feita à uma determinada distância do alvo (Von Bueren et al., 2015).

Os índices de vegetação consistem em operações algébricas com os valores obtidos de diferentes faixas do espectro, como por exemplo as regiões do visível e infravermelho próximo, também denominadas de bandas espectrais. Os resultados destas operações podem ser correlacionados com parâmetros da cultura, como por exemplo, quantidade e sanidade de biomassa, cobertura de dossel e teor de clorofila quando a imagem foi coletada (Maimaitijiang et al., 2017).

Existe grande variedade de índices e esta variedade cresce à medida que novos estudos são realizados. Um índice muito usado é o MPRI (Modified Photochemical Reflectance Index), que é um bom parâmetro para se quantificar a cobertura verde de uma área (Gonçalves et al., 2017). O índice MPRI é calculado através dos valores refletidos no comprimento de ondas da região do verde e do vermelho.

Outro índice que tem sido muito explorado na agricultura é o NDVI (Normalized Difference Vegetation Index). Este índice usa o vermelho, que está dentro do espectro visível e o infravermelho próximo que tem comprimento de onda na faixa de 725 a 1100 nm. O índice NDVI pode ser correlacionado com produtividade de milho. Em estudos com áreas comerciais, observou-se correlação entre maiores produtividades e regiões que apresentaram maiores índices de NDVI (Sangoi et al., 2011). Também, utilizando de índices extraídos de imagens foi possível fazer predições sobre diversas características de soja, dentre elas a produtividade, teor de óleo e maturação relativa em dias (Yuan et al., 2019). Através da análise de imagens

associada a técnicas de redes neurais foi possível obter bons resultados de predição de maturação de soja (Trevisan et al., 2020).

2.5.3 Representação de Cores RGB

A diferenciação da cor se dá em função de características do corpo no qual a luz é projetada. O corpo pode refletir certos comprimentos de ondas e absorver outros, expressando as cores que o olho humano é capaz de enxergar. Para representar graficamente este sistema de cores, foi criado o sistema RGB do inglês red, green e blue. As cores podem também ser representadas por outros sistemas como por exemplo o sistema CMY, do inglês Cyan, Magenta e Yellow (Rocha, 2013). Estes modelos são capazes de representar as cores que o olho humano é capaz de enxergar.

Por se tratar de uma classificação aditiva, o sistema RGB é o mais utilizado em equipamentos eletrônicos, como máquinas fotográficas digitais, TV's e computadores. Este sistema é muito utilizado em imagens digitais as quais são compostas por pixels, cada um composto por três valores que representam a intensidade de vermelho, verde ou azul, respectivamente refletidos.

A representação mais comum é a de 8 bits que permite o total de 256 variações para cada cor, variando de 0 a 255 (Gonzales et al., 2000). Tanto o modelo RGB, quanto o modelo CMY são representados por gráficos com três dimensões conforme mostrado na figura 2.




Figura 2. Representação 3D do sistema de cores RGB (Corrêa et al., 2014)

O modelo RGB de 8 bits é capaz de representar o total de 16,77 milhões de cores (256x256x256), sendo que os valores mais próximos de zero se tem a cor preta e os valores mais próximos de 255 o branco.

Uma forma didática para se compreender o sistema RGB, é o exemplo da figura 3, em que se tem um objeto vermelho, que ao receber iluminação refletirá com maior intensidade o vermelho e absorverá as demais cores como o verde e o azul.




Figura 3. Reflexão e absorção de cores RGB (Rocha, 2013).

2.5.4 A Coloração das Plantas e a Clorofila

A clorofila é o pigmento com maior abundância no meio ambiente e tem como principal papel a captação da luz para conversão de energia luminosa em energia química no processo conhecido como fotossíntese. Nas plantas superiores a clorofila fica localizada nos plastídeos, que por conta da coloração verde também são chamados de cloroplastos (Borrmann, 2009).

A clorofila está ligada a proteínas de forma não covalente, e acompanhada de carotenoides. As plantas verdes contêm, principalmente a clorofila a, que corresponde a 75% dos pigmentos verdes totais, e a clorofila b, que é um pigmento complementar. A clorofila a tem maior absorção de luz na faixa de 400 e 450 nm, enquanto a clorofila tipo b na faixa de 450 a 480 nm (Gross, 1991).

Durante o ciclo de vida de uma planta a clorofila é sintetizada e a partir de algum momento também ocorre a degradação, em processo denominado de senescência. A degradação natural

da clorofila visa o aumento da solubilidade do pigmento e o encerramento das suas propriedades fotodinâmicas. A degradação também pode ocorrer por fatores externos como déficit hídrico, redução de luz, alterações na temperatura e aumento do teor de etileno (Takamiya et al., 2000).

As características fotodinâmicas da clorofila podem se tornar ameaça durante o processo de senescência, desta forma, a degradação da clorofila pode ser considerada um processo de detoxificação (Hortensteiner et al., 2004).

A degradação da clorofila é mais facilmente visualizado em folhas, pois estas partes têm maiores quantidades desta substância, quando se compara, por exemplo, com as sementes (Krautler, 2002).

3.MATERIAL E MÉTODOS

Os dados foram coletados na safra 2018/19 em experimento conduzido na região de Rio Verde Goiás, latitude -17.806175, longitude -50.903431 e altitude de 745 metros. O município está situado na macrorregião sojícola 3 e microrregião 301, conforme a terceira aproximação do zoneamento agrícola, proposta por (Kaster & Farias, 2011). Na região, predomina o solo do tipo Latossolo Vermelho Distrófico com relevo plano, levemente ondulado. A temperatura média observada é de 22.3°C e precipitação anual de 1600 milímetros (Soma Brasil, 2021). O plantio foi realizado no dia 20 de outubro de 2018, época adequada para o plantio de soja na região. Os tratamentos culturais foram feitos no intuito de se obter o máximo potencial produtivo da cultura, de acordo com o manejo proposto para a região do cerrado Brasileiro (EMBRAPA, 2014).

No experimento foram plantadas 34 cultivares de soja com grupos de maturação relativa variando de 6.6 a 8.5. O delineamento experimental usado foi o de blocos ao acaso com três repetições. As parcelas foram constituídas de 2 linhas de 4 metros de comprimento, espaçadas em 0,5 m entre si e com população final de 300.000 plantas ha⁻¹.

Foram realizados cinco voos para coleta de imagens do experimento, sendo o primeiro voo aos 59 dias e os demais aos 76, 90, 104 e 114 dias respectivamente (Tabela 1).

1.Tabela 1. Quantidade de dias desde o plantio e as respectivas datas dos voos realizados para coleta de imagens do ensaio.

	DAP	Data
Voo 1	59	18/12/2018
Voo 2	76	04/01/2019
Voo 3	90	18/01/2019
Voo 4	104	01/02/2019
Voo 5	114	11/02/2019

DAP: Dias após o plantio

Os planos de voos foram feitos com o software Drone Deploy® (Drone Deploy, 2021) a altura de 30 metros e com sobreposição de imagens de 80% frontal e 80% lateral com velocidade de 3 m s⁻¹. O equipamento de voo utilizado foi um drone Phantom 4 Advanced equipado com câmera RGB (red, green e blue) com resolução de 5472 × 3648 pixels (DJI, 2021) que possibilitou a obtenção de um GSD (ground sample distance) de 1,2 centímetros. Os voos foram realizados preferencialmente entre as 10 e as 14 horas para minimizar o efeito da sombra gerado pela inclinação do sol sobre os objetos.

O software Pix4d (Pix4d SA, 2021) foi utilizado para geração dos ortomosaicos que, posteriormente foram processados no software QGIS (QGIS, 2021) e foi realizada a extração dos valores médios de cada uma das bandas RGB referentes a cada linha das parcelas do ensaio. Para fins de normalização, os valores obtidos foram divididos por 255, pois este é o valor máximo em decimal para a representação RGB de 8 bits. As análises foram feitas em Python, utilizando, principalmente as bibliotecas, Pandas, Numpy, Matplotlib e Scikit-learn e, também o software R (R-project, 2021) com a biblioteca Lme4.

Foi criado um índice para representar a maturação relativa teórica de cada cultivar no dia de cada um dos voos. Esse índice foi calculado com base nos estudos de Alliprandini et al. (2009), que concluiu que a cada 0.1 de variação no grupo de maturação relativa, têm-se em média 15,5 dias de diferença no ciclo da soja. O cálculo do índice de maturação foi feito de acordo com a equação a seguir:

$$Mtindex = \frac{DAP}{RM * 15,5}$$

Em que Mtindex é o índice de maturação teórico calculado para cada cultivar no dia do voo, DAP é a quantidade de dias desde o plantio até o dia do voo e RM é a maturação relativa de cada cultivar, informado por cada desenvolvedor. Os índices de maturação teóricos calculados para cada grupo de maturação relativa nos respectivos voos são mostrados na tabela 2.

Tabela 2. Mtindex calculado para cada grupo de maturação relativa no dia dos respectivos voos.

Maturação Relativa	Dias Previstos para Maturação	Quantidade de Dias Desde o Plantio				
		59	76	90	104	114
Índice de Maturação Teórico Calculado Para o Dia (Mtindex)						
6.6	102	0.58	0.74	0.88	1.02	1.11
6.8	105	0.56	0.72	0.85	0.99	1.08
7.2	112	0.53	0.68	0.81	0.93	1.02
7.3	113	0.52	0.67	0.80	0.92	1.01
7.4	115	0.51	0.66	0.78	0.91	0.99
7.5	116	0.51	0.65	0.77	0.89	0.98
7.6	118	0.50	0.65	0.76	0.88	0.97
7.9	122	0.48	0.62	0.73	0.85	0.93
8	124	0.48	0.61	0.73	0.84	0.92
8.1	126	0.47	0.61	0.72	0.83	0.91
8.2	127	0.46	0.60	0.71	0.82	0.90
8.3	129	0.46	0.59	0.70	0.81	0.89
8.4	130	0.45	0.58	0.69	0.80	0.88
8.5	132	0.45	0.58	0.68	0.79	0.87

Valores de Mtindex inferiores a 1 indicam que naquele dia a cultivar não estava madura, enquanto valores superiores a 1 indicam que o voo foi feito após a maturação teórica para aquele grupo de maturação relativa, com base nos estudos de Alliprandini et al., (2009) que indicaram o total de 15,5 dias para cada 0.1 de variação na maturação relativa

Como a temperatura média ao longo do ciclo é um dos fatores que tem grande influência no desenvolvimento da soja, foi incluído o parâmetro calor acumulado desde o plantio até a data de cada voo. Esta quantidade de calor foi calculada, somando os valores diários acumulados até as respectivas datas dos voos. A soma térmica diária acumulada foi calculada pela equação:

$$UCD = T_{média} - 14$$

Em que: UCD são as unidades de calor acumulada no dia, T média é a temperatura média diária e a constante 14 foi usada como a temperatura base de desenvolvimento para a cultura da soja,

por ser o valor que melhor representou a temperatura base para soja de acordo com os estudos de Camargo et al., (1987).

A soma térmica total foi calculada somando todas as unidades de calor diárias desde um dia após o plantio até a data de cada voo. Para o cálculo da soma térmica total, utilizou-se a equação:

$$SomaTérmica = \sum_{i=1}^n (UCD)$$

Em que: SomaTérmica é a quantidade de calor acumulado no período, UCD é o total de calor acumulado em cada dia e n é a quantidade de dias desde o plantio até a data do voo. Os totais acumulados de calor para cada voo são mostrados na tabela 3.

Tabela 3. Quantidade de calor acumulado até a data de cada voo, considerando temperatura base de 14°C.

	DAP	Data	SomaTérmica
Voo 1	59	18/12/2018	570
Voo 2	76	04/01/2019	741
Voo 3	90	18/01/2019	884
Voo 4	104	01/02/2019	1031
Voo 5	114	11/02/2019	1134

DAP: Quantidade de dias após o plantio
GD: Total de calor acumulado

As temperaturas médias foram obtidas na base do Instituto Nacional de Meteorologia (Inmet, 2021), coletados de uma estação meteorológica instalada no município de Rio Verde Latitude: -17.785303 e Longitude: -50.964869.

Através das informações de RGB capturadas nas imagens foi calculado o índice VARI (Visible Atmospherically Resistant Index). O índice VARI é um bom parâmetro para mensuração de cobertura verde de uma superfície (Gitelson et al., 2001). O cálculo do índice VARI é feito pela equação:

$$VARI = \frac{G - R}{G + R - B}$$

Em que: R, G e B são respectivamente os valores refletidos de vermelho, verde e azul.

Optou-se pela geração de um polígono para cada linha do ensaio e como cada parcela foi composta por duas linhas com três repetições e foram testadas 34 cultivares, obteve-se o total geral de 204 polígonos. Com os cinco voos realizados foi possível a captura de 923 observações em diferentes momentos do ciclo das parcelas. O total planejado foi de 1020 polígonos, porém alguns dados foram perdidos no decorrer do experimento.

Os dados foram separados aleatoriamente em dois conjuntos sendo 70% de dados para treino e 30% de dados para teste. Para diminuição da escala dos valores de RGB capturados, os mesmo foram divididos por 255 e foram identificados com Rn, Gn e Bn respectivamente. Foram definidas como variáveis preditoras os parâmetros DAP, Soma Térmica, Rn, Gn, Bn e o índice VARI. A variável target foi o índice de maturação teórico (Mtindex) calculado para cada cultivar em cada momento de voo.

Os dados foram submetidos a análise de regressão múltipla em Python e análise de regressão linear mista em R com o intuito de identificar a capacidade de predição da variável target Mtindex, através das variáveis preditoras.

4.RESULTADOS E DISCUSSÃO

Ao observar os valores médios refletidos de R, G e B ao longo do ciclo, dentro de cada grupo de maturação relativa, observa-se que a combinação RGB capturada em cada voo expressa a alteração de cor das plantas de soja, sendo que no primeiro voo, as cultivares do grupo de maturação relativa 6.6 apresentaram em média os valores R=68, G=125 e B=95. Esta combinação RGB representa um tom de verde, esperado para este grupo de maturação relativa aos 59 dias de plantado. Ainda dentro do grupo de maturação 6.6, foi observado que no voo aos 104 dias após o plantio, a combinação RGB média obtida foi de R=170, G=133 e B=88. Esta combinação RGB representa um tom de marrom similar à coloração de plantas maduras, que é esperado para cultivares de maturação relativa 6.6 aos 104 dias após o plantio na região de Rio Verde GO.

Já analisando as cultivares mais tardias, do grupo de maturação relativa 8.5, foi observado que mesmo no voo aos 104 dias após o plantio, os valores RGB médios obtidos representaram ainda um tom de verde, e demonstra que estas cultivares por terem um ciclo maior, permaneceram verdes por mais tempo. Os valores RGB médios para cada grupo de maturação, juntamente com suas representações de cores são mostrados na figura 4.

GM	59 dias apos plantio			76 DAP dias após plantio			90 dias após plantio			104 dias após plantio			114 dias após plantio		
	R	G	B	R	G	B	R	G	B	R	G	B	R	G	B
6.6	68	125	95	101	153	113	129	124	56	170	133	88			
6.8	91	142	99	95	148	106	108	106	47	140	127	51	141	120	57
7.2	74	126	86	90	143	97	102	103	48	148	133	57	147	119	60
7.3	76	127	87	95	150	102	106	102	46	136	123	53	137	119	52
7.4	82	135	87	83	140	86	104	103	40	136	127	44	150	125	55
7.5	86	140	96	99	152	102	95	97	45	121	116	48	129	121	49
7.6	68	121	81	97	150	104	111	109	48	147	129	54	129	105	51
7.9	78	130	90	88	147	104	96	100	47	110	109	46	114	109	48
8	85	135	96	88	149	109	98	104	50	125	125	50	131	124	46
8.1	83	138	96	87	148	107	89	94	46	106	108	46	108	112	42
8.2	87	145	98	90	149	99	93	99	45	115	115	47	120	119	44
8.3	81	135	91	96	153	110	103	108	52	123	124	52	124	117	48
8.4	80	132	90	105	163	113	102	108	49	118	121	53			
8.5	83	135	94	93	155	102	89	97	44	100	104	47	95	103	43

Figura 4. Valores médios de RGB para cada grupo de maturação e suas representações em cores

O índice VARI se mostrou adequado para visualização da diferenciação de ciclo conforme é mostrado na figura 6. As cultivares mais precoces do grupo de maturação relativa 6.8 por exemplo, apresentaram decréscimo nos valores médios de índice VARI antecipadamente, quando comparado as cultivares mais tardias, como por exemplo as cultivares de maturação relativa 8.5, conforme mostrado na figura 5.




Figura 5: Índices VARI médios de cultivares do grupo de maturação 6.8, 7.3, 7.6 e 8.5 em dias após o plantio.

As variáveis preditoras DAP, Soma Térmica, R, G e VARI foram significativas para a predição da variável target conforme mostrado na tabela 4.

Tabela 4. Análise de variância dos dados.

Variável	sum_sq	df	F	PR(>F)
DAP	0.094145	1	43.287373	7.94E-11
SomaTermica	0.076624	1	35.231272	4.15E-09
Rn	0.340441	1	156.533268	2.86E-33
Gn	0.171913	1	79.044865	3.17E-18
Bn	0.000017	1	0.00783	9.30E-01
VARI	0.087912	1	40.421549	3.22E-10
Residual	1.992188	916	NaN	NaN

Quando aplicado a regressão linear múltipla com a biblioteca Scikit-learn do Python foi possível prever a variável target (Mtindex) com um R^2 de 0.92 e um RMSE de 0.009. A equação para cálculo da predição ficou da seguinte forma:

$$\text{Mtindex_Pred} = \text{DAP} * 0.05797 - \text{SomaTermica} * 0.00497 + \text{Rn} * 0.88423 - \text{Gn} * 0.55242 + \text{Bn} * 0.01225 + \text{VARI} * 0.25187 - 0.19384$$

Em que: Mtindex_Pred é o índice de maturação relativa predito no dia do voo, DAP é a quantidade de dias desde o plantio até a data do voo, Soma Térmica, é o total de calor acumulado desde um dia após o plantio até a data voo, os valores Rn, Gn e Bn, são respectivamente os valores normalizados de vermelho, verde e azul e VARI é o índice de resistência atmosférica na faixa do visível calculado. A figura 6 mostra o resultado do modelo aplicado no conjunto de dados de teste.




Figura 6: Comparação dos dados observados e preditos pelo modelo.

Aplicando o modelo no conjunto total de dados, também foi observado uma boa capacidade de predição. Na figura 7 é mostrado a comparação dos dados observados e preditos pelo modelo. Neste cenário foi obtido um R2 de 0.93 e um RMSE de 0.013.




Figura 7: Modelo aplicado no conjunto total de dados.

Os parâmetros de maior influência na predição do Mtindex, foram Rn, Gn e índice VARI, conforme observado nos coeficientes angulares calculados para cada parâmetro, conforme tabela 5.

Tabela 5. Coeficientes angulares para as variáveis predictoras.

Parâmetro	Coefficiente Angular
DAP	0.05797538
SomaTermica	-0.00497213
Rn	0.88422913
Gn	-0.5524213
Bn	0.01225183
VARI	0.25186923

Os dados de índice de maturação preditos foram usados para calcular a maturação relativa de cada cultivar conforme a equação:

$$RMpred = \frac{DAP}{Mtindex_Pred * 15,5}$$

Em que: RMpredito é a maturação relativa calculada com base no Mtindex predito, DAP é a quantidade de dias desde o plantio até a data do voo, Mtindex_Pred é o índice de maturação relativa predito pelo modelo para cada cultivar em cada data. As maturações relativas calculadas dentro de cada grupo são mostradas na figura 8.




Figura 8: RM real comparado com o RM calculado com base no Mtindex predito

Aplicando os dados a um modelo de regressão linear misto da biblioteca Lme4 do R, houve pequena diferenciação na significância dos parâmetros. Neste caso a variável Bn não foi significativa conforme é mostrado na tabela 6.

Tabela 6. Análise de variância obtida pela biblioteca Lme4 do R.

	Sum Sq	Mean Sq	NumDF	DenDF	F value	Pr(>F)
DAP	0.009069	0.009069	1	885.23	82.9312	< 2.2e-16***
SomaTérmica	0.0037148	0.0037148	1	885.24	33.9705	0.000000007833***
Rn	0.0114113	0.0114113	1	885.91	104.3509	< 2.2e-16***
Gn	0.0047956	0.0047956	1	885.82	43.8535	0.000000000613***
Bn	0.000126	0.000126	1	885.46	1.1525	0.2833
VARI	0.0024907	0.0024907	1	885.44	22.7762	0.2128E-6***

O modelo linear misto do R teve uma performance melhor para predição do Mtindex com base nos parâmetros DAP, Soma Térmica, Rn, Gn, Bn e VARI com um R^2 próximo de 1, conforme mostrado na figura 9.




Figura 9: Resultado da aplicação de um modelo de regressão mista em R

A equação obtida para predição do índice de maturação (Mtindex) com o modelo misto em R foi:

$$\text{Mtindex_Pred} = \text{DAP} * 0.02248 - \text{SomaTérmica} * 0.00140 + \text{Rn} * 0.19249 - \text{Gn} * 0.11191 + \text{Bn} * 0.0119 + \text{VARI} * 0.04897 - 0.05703$$

Da mesma forma, foi calculado a maturação relativa de cada cultivar com base no Mtindex predito para cada data de voo. Os valores obtidos são mostrados na figura 10.




Figura 10: Maturação relativa calculada com base no Mtindex predito com R.

Com relação as datas de voos, os índices preditos apresentaram pouca diferente de performance dentro dos grupos de maturação relativa estudados. Na figura 11 são mostradas as

comparações entre o Mtindex observado e o Mtindex predito para os grupos de maturação 6.6, 6.8, 7.2 e 7.3. Observou-se que a melhor performance de predição do índice de maturação para estes grupos foi nos voos realizados por volta dos 80 dias, após o plantio.

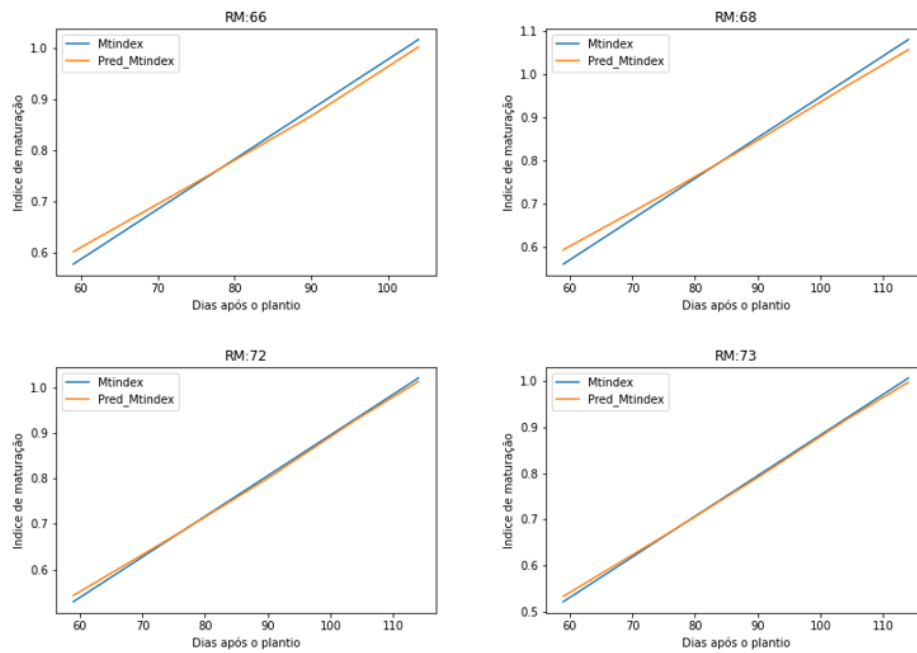


Figura 11. Comparação de Mtindex observado e predito para os grupos de maturação 6.6, 6.8, 7.2 e 7.3.

Já os grupos de maturação 7.4, 7.5, 7.6 e 7.9 a performance de predição do índice de maturação foi muito boa em todos os voos pois o Mtindex predito foi similar ao Mtindex observado, conforme demonstrado na figura 12.

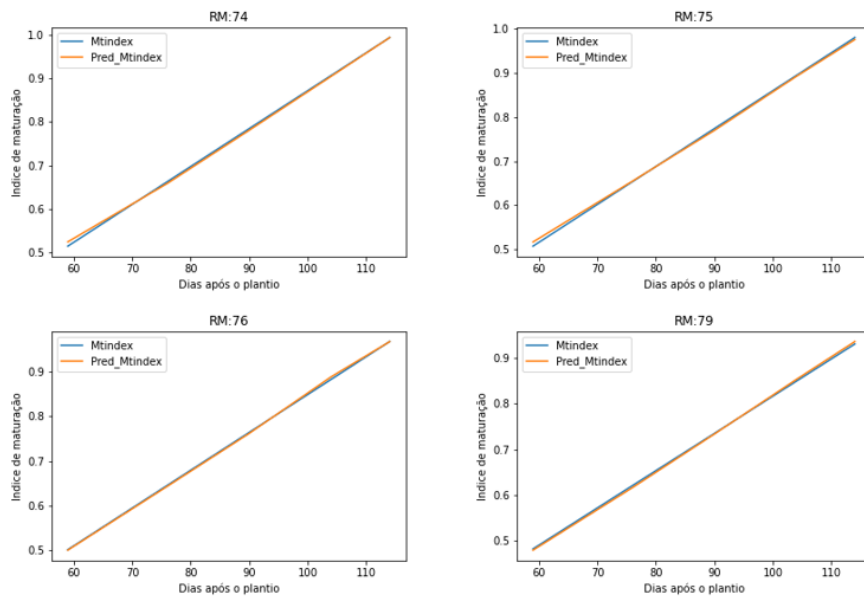


Figura 12. Comparação de Mtindex observado e predito para os grupos de maturação 7.4, 7.5, 7.6 e 7.9.

Para os grupos de maturação 8.0 e 8.1, a performance de predição também foi boa em todos os voos. Já, para os grupos 8.2 e 8.3, a melhor performance de predição foi em voos aos 90 dias. A figura 3 mostra a comparação de Mtindex observado e predito para os grupos de maturação relativa 8.0, 8.1, 8.2 e 8.3.




Figura 13. Comparação de Mtindex observado e predito para os grupos de maturação 8.0, 8.1, 8.2 e 8.3.

Para o grupo de maturação relativa 8.4, a melhor predição foi por volta dos 85 dias e para o grupo 8.5 aos 90 dias. A comparação Mtindex observado e o predito para estes dois grupos é mostrada na figura 14.




Figura 14. Comparação de Mtindex observado e predito para os grupos de maturação 8.4 e 8.5.

Os resultados obtidos através de ambas as metodologias de predição foram superiores aos obtidos por Yuan et al. (2019) e foi possível predizer a maturação em dias, com um R^2 de 0.756. Outra vantagem da metodologia desenvolvida, é a possibilidade de fazer a predição com apenas um voo ao longo do desenvolvimento da cultura.

5.CONCLUSÃO

Com base nos resultados obtidos, conclui-se que foi possível prever a maturação relativa de diferentes cultivares de soja, plantadas nas mesmas condições, usando imagens RGB (red, green e blue) capturadas com VANT, associado com a soma térmica acumulada desde o plantio até a data do voo.

O índice VARI, calculado através dos valores refletidos de RGB se mostrou uma ferramenta adequada para visualizar a diferenciação de coloração de cultivares de soja de diferentes grupos de maturação relativa ao longo do ciclo. A diferenciação de coloração de dossel é uma característica que tem alta correlação com o amadurecimento da soja e o índice VARI pode ser usado como parâmetro para classificação de maturação relativa, se associado com outras variáveis como dias desde o plantio, soma térmica acumulada e valores refletidos de RGB em um determinado momento ao longo do ciclo da soja.

O modelo de regressão linear múltipla, calculado no Python com a biblioteca Scikit-learn gerou uma predição com R^2 de 0.92 em RMSE de 0.009, sendo a equação do modelo:

$$\text{Mtindex_Pred} = \text{DAP} * 0.05797 - \text{SomaTérmica} * 0.00497 + \text{Rn} * 0.88423 - \text{Gn} * 0.55242 + \text{Bn} * 0.01225 + \text{VARI} * 0.25187 - 0.19384$$

Já usando a biblioteca Lme4 (Bates et al., 2015) do R, aplicando um modelo misto de regressão linear, foi possível obter uma predição de maturação relativa para soja excelente, com um R^2 de 0.996. A equação obtida através do modelo misto em R foi:

$$\text{Mtindex_Pred} = \text{DAP} * 0.02248 - \text{Soma Térmica} * 0.00140 + \text{Rn} * 0.19249 - \text{Gn} * 0.11191 + \text{Bn} * 0.0119 + \text{VARI} * 0.04897 - 0.05703$$

Também foi possível concluir que o valor de 15,5 dias por cada 0.1 de maturação relativa descrito por Alliprandini et al., (2009) é um valor adequado para representar a diferenciação em dias para os grupos de maturação relativa, nas condições em que o experimento foi realizado.

A Soma Térmica acumulada também é um importante fator que pode colaborar com o cálculo de maturação relativa de cultivares de soja ajustando o modelo para ambientes com

diferentes condições climáticas. Esta variável contribui para a aplicação da metodologia em ambientes com temperaturas médias diferentes, e até mesmo para o mesmo local em diferentes anos, e, é possível ocorrer um comportamento climático diferente.

Com relação ao momento ideal de voo, de uma forma geral, concluiu-se que os melhores resultados de predição foram obtidos com dados de imagens capturadas nos voos realizados entre 80 e 90 dias após o plantio.

6. CONSIDERAÇÕES FINAIS

O estudo foi realizado em um grupo de cultivares de maturação relativa variando de 6.6 a 8.5 e com imagens capturadas em voos realizados aos 59,76,90,104 e 114 dias após o plantio. Desta forma, espera-se que ambos os modelos desenvolvidos ofereçam boa capacidade de predição para situações semelhantes ao do estudo.

A metodologia da pesquisa pode ser aplicada para geração de modelos para outras regiões, porém a recomendação é que se faça uma calibração para cada ambiente de interesse, pois as diferenças climáticas e geográficas têm forte influência no desenvolvimento da soja.

Os valores de maturação relativa usados, foram os informados pelos detentores das cultivares. Estes valores são definidos de forma genérica, e pode ser que haja variações de região para região. Novos estudos podem ser feitos com o intuito de validar as maturações relativas das cultivares e realizar uma nova calibração do modelo para ambientes específicos.

O estudo se baseou dentre outros fatores, na alteração de coloração de dossel ao longo do ciclo, característica esta que tem alta correlação com a maturidade da soja. Vale ressaltar que alterações de coloração podem ser causadas por outros fatores bióticos e abióticos, como por favor exemplo aplicação de herbicidas, presença severa de doenças, presença de plantas invasoras e infestação de nematoides. Desta forma, ao aplicar os modelos desenvolvidos é necessário observar estas fontes de variação de coloração do dossel.

6.REFERÊNCIAS BIBLIOGRÁFICAS

Alliprandini, L.F., C. Abatti, P. F. Bertagnolli, J. E. Cavassim, H. L. Gabe, A. Kurek, M. N. Matsumoto, M.A.R. de Oliveira, C. Pitol, L.C. Prado & C. Steckling. 2009. Understanding soybean maturity groups in Brazil: environment, cultivar classification, and stability. *Crop Science*, 49:801-808 p.

Apex Ensino. 2021. Disponível em <<https://apexensino.com.br/voce-conhece-a-linguagem-python/>> acesso em 23 abril 2021.

Aprosoja, 2020. Disponível em: <<https://aprosojabrasil.com.br/a-soja/>> Acesso em 5 de setembro 2020.

Aquino, A., B. Millan, M. Diago & J. Tardaguila. 2018. Automated early yield prediction in vineyards from on-the-go image acquisition. *Comput. Electron. Agric.* 144:26–36 p.

Bai, G., S. Jenkins, W. Yuan, G.L. Graef & Y. Ge. 2018. Field-Based Scoring of Soybean Iron Deficiency Chlorosis Using RGB Imaging and Statistical Learning. *Front. Plant Sci.* 9:1002.

Bates, D., M. Mächler, B. Bolker, S. Walker. 2015. Fitting Linear Mixed-Effects Models Using lme4. *Journal of Statistical Software*, 67, 1–48 p.

Bonato, E.R. & A.L.V. Bonato. 1987. A soja no Brasil: História e Estatística. EMBRAPA-CNPSO Documentos, 21:61p.

Borrmann, D. 2009. Efeito de déficit hídrico em características químicas e bioquímicas da soja e na degradação da clorofila, com ênfase na formação de metabólitos incolores. 2009. Tese de doutorado faculdade de ciências farmacêuticas-USP.

Camargo, B.P. O. Brunini & M.A.C. Miranda. 1987. Temperatura-Base Para Cálculo dos Graus-Dia Para Cultivares em São Paulo. *Pesq. Agropec. Bras.*, Brasília, 22(2): 115-121 p.

Candiago, S. F. Remondino, M. De Giglio, M. Dubbini, M. Gatteli. 2015. Evaluating Multispectral Images and Vegetation Índices for Precision Farming Application from UAV Images. *Remote Sensing*, v.7, 4026-4047 p.

Chaudhary, P., A.K. Chaudhari, A.N. Cheeran. & S.C. Godara. 2012. Transform Based Approach for Disease Spot Detection on Plant Leaf. *Int. J. Comput. Sci. Telecommun.* 3:65–71 p.

Corrêa, J.H.G, G.U.S. Veja, N.S. Cunha, T.G. da Silva, P.D. Maciel Jr. 2014. Um modelo simples e parametrizável para classificação de cores no sistema RGB. IX Congresso Norte Nordeste de Pesquisa e Inovação, 2014.

Daffert, F.W. 1892. Relatório anual do Instituto Agrônômico do Estado de São Paulo. Campinas, 26p.

Dornhofer, K., N. Oppelt. 2016. Remote Sensing for Lake Research and monitoring – Recent Advances. Ecological Indicators, v. 64, 105-122 p.

DJI. 2021. Disponível em < www.dji.com/br > acesso em 23 de abril 2021

Drone Deploy. 2021. Disponível em < <https://www.dronedeploy.com/> > acesso em 23 de abril 2021

D’utra, G. 1882. Soja. Jornal do Agricultor. 4(168) :185 -6

EMBRAPA, 2007. Ecofisiologia da Soja. Circular Técnica 48.

EMBRAPA. 2014. Tecnologias de Produção de Soja Região Central do Brasil. Disponível em: < <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/95489/1/SP-16-online.pdf> > acesso em 23 abril 2021.

EMBRAPA. 2020. Características da soja. Disponível em: < https://www.agencia.cnptia.embrapa.br/gestor/soja/arvore/CONTAG01_24_271020069131.html > Acesso em 11 setembro de 2020.

Esteves, E.A. & J.B.R. Monteiro. 2001. Efeitos benéficos das isoflavonas de soja em doenças crônicas. Rev Nutr. 14:43-52 p.

Franchini, J.C., A.A.B. Junior, L.A.C. Jorge, H. Debiassi, W.P. Dias, C.V. Godoy, A.O. Junior, F.B. Corrêa, M.C.N. de Oliveira. 2018. Uso de imagens aéreas obtidas com drones em sistemas de produção de soja. Embrapa Soja (Doc 408). Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/190247/1/Doc-408-OL-alta.pdf>> acesso em: 26 agosto 2020.

Furlanetto, R.H., M.R. Nanni, L.G.TÇ. Crusiol, G.F.C. Silva, ; A. de Oliveira Junior. 2017. Potencial de utilização de sensores multiespectral e hiperespectral no estudo de diferentes alvos agrícolas. EMBRAPA Soja, 2017.

Gitelson, A.A, Y.J. Kaufman, R. Stark, D. Rundquist. 2002. Novel algorithms for remote estimation of vegetation fraction. Remote Sensing of Environment 80: 76-87 p.

Gomes, J.V.S. et al. 2016. Classificação do Ciclo da Soja Baseado no Grupo de Maturidade Relativa. Embrapa Meio-Norte, 2016. 60 p. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/156503/1/69-a-71.pdf>>. Acessado em 27 de maio de 2020.

Gonzalez, R.C., R.E. Weeks, R.M. Cesar Junior, L.F Costa. 2000. Processamento de imagens digitais. São Paulo: E. Blucher.

Gross, J. 1991. Pigments in vegetables: Chlorophylls and carotenoids. New York: Van Nostrand Reinhold, 1991. 351p

Hamuda, E., M. Glavin, E., Jones. 2016. A survey of image processing techniques for plant extraction and segmentation in the field. *Comput. Electron. Agric.* 125: 184–199.

Hörtensteine, S. 2004. The loss of green color during chlorophyll degradation: A prerequisite to prevent cell death? *Planta* 219: 191–194 p.

Huihui, L., A. Rasheed, L.T. Hickey & Z. He. 2018. Fast-Forwarding Genetic Gain Volume. *Trends Plant Sci.* 23:184-186. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S1360138518300190?pes=vor>> Acesso em 23 agosto 2020.

Hymowitz, T. 1970. On the domestication of the soybean. *Economic Botany*, 24:408 p.

Hunt, E.R.J., M. Cavigelli, C.S.T. Daughtry, J.I. McMurtrey & C.L. Walthall. 2005. Evaluation of Digital Photography from Model Aircraft for Remote Sensing of Crop Biomass and Nitrogen Status. *Precis. Agric.* 6:359–378 p.

Inmet. 2021. Instituto Nacional de Meteorologia. Disponível em < <https://portal.inmet.gov.br/> > acesso em 23 de abril 2021

Jorge, L.A.C, R.Y. Inamasu.2014. Uso de Veículos Aéreos Não Tripulados (VANT) na Agricultura. *EMBRAPA.* 109-134 p.

Kaster, M. & J.R.B. Farias. 2011. Regionalização dos testes de Valor de Cultivo e Uso e da indicação de cultivares de soja – Terceira Aproximação. *Embrapa Soja.* 69 p.

Krätler, B. 2002. Unravelling chlorophyll catabolism in higher plants. *Biogchemical Society Transactions*, V. 30, 625-630 p.

Ma, B.L., L. M. Dwyer, C. Costa, E. R. Cober & M. J. Morrison. 2001. Early Prediction of Soybean Yield from Canopy Reflectance Measurements. *Agron. J.* 93:1227–1234 p

Maimaitijiang, M., A. Ghulam, P. Sidike, S. Hartling, M. Maimaitiyiming, K. Peterson, E. Shavers, J. Fishman, J. Peterson, S. Kadam, J. Burken, F. Felix. 2017. 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, 43-58 p.

Miyasaka, S. J. C. Medina. 1981. A Soja no Brasil. *Campinas, ITAL.* P.129-42

Morais, A.A.C. & A.L. Silva. 2000. Valor nutritivo e funcional da soja. *Rev. bras. nutr. Clín*, 15(2): 306-15. Disponível em:

<<https://pesquisa.bvsalud.org/portal/resource/pt/lil-269041>> Acesso em 5 setembro 2020.

Morse, W.J. 1950. History of soybean production. *Soybeans and soybean products.* New York, Interscience. 3:59 p.

Nepomuceno A.L., J.R.B. Farias & N. Neumaier. 2020. Características da soja. *EMBRAPA.* Disponível em:

<https://www.agencia.cnptia.embrapa.br/gestor/soja/arvore/CONTAG01_24_271020069131.html> acesso em: 6 setembro 2020

Numpy. 2021. Disponível em < <https://numpy.org/> > acesso em 23 de abril 2021

- Pandas. 2021.** Disponível em < <https://pandas.pydata.org/> > acesso em 23 de abril 2021
- Piper, C.V. & Morse, W.J, 1923.** The soybean. New York, McGraw Hill. 320 p.
- Pix4D SA. 2021.** Disponível em < www.pix4d.com > acesso em 23 de abril 2021
- QGIS. 2021.** Disponível em < <https://qgis.org/en/site/> > acesso em 23 de abril 2021
- Ray D.K., N.D Mueller, P.C. West & J.A. Foley. 2013.** Yield Trends Are Insufficient to Double Global Crop Production by 2050. PLOS ONE 8(6): 66428. Disponível em: <<https://doi.org/10.1371/journal.pone.0066428>> Acesso em: 23 agosto 2020.
- Rivero S., O. Almeida, S. Ávila & W. Oliveira. 2009.** Pecuária e desmatamento: uma análise das principais causas diretas do desmatamento na Amazônia. Nova econ. vol.19 no.1 Belo Horizonte Jan./Apr. 2009. Disponível em: <https://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-63512009000100003> acesso em 23 agosto 2020.
- Rocha, J.C. 2010.** Cor Luz, Cor Pigmento e os Sistemas RGB e CMY. Revista Ano 2, n.3, maio 2010. Disponível em: <<https://www.belasartes.br/revistabelasartes/?pagina=player&slug=cor-luz-cor-pigmento-e-os-sistemas-rgb-e-cmy>> acesso em abril 2021.
- R-project . 2021.** Disponível em < <https://www.r-project.org/> > acesso em 23 de abril 2021.
- Saa, S., P.H. Brown, S. Muhammad, A.O. Rio, B.L. Sanden & E.A. Laca. 2014.** Prediction of leaf nitrogen from early season samples and development of field sampling protocols for nitrogen management in Almond (*Prunus dulcis* [Mill.] DA Webb). Plant and Soil 380:153–163 p.
- Samseemoung, G., P, Soni., H.P.W. Jayasuriya, V.M. Salokhe. 2012.** Application of low altitude remote sensing (LARS) platform for monitoring crop growth and weed infestation in a soybean plantation. Precision Agriculture, v. 13, 611-627 p.
- Sadras, V.O., G.J. Rebetzke, G.O. Edmeade. 2013.** The phenotype and the components of phenotypic variance of crop traits. Field Crops Research 154: 255-259. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0378429013003420?via%3Dihub>> acesso em 24 agosto 2020.
- Sangoi, L., C. Schweitzer, P.R.F. Silva, A. Schmitt, V.P. Vargas, R.T. Casa, C.A. Souza. 2011.** Perfilamento, área foliar e produtividade do milho sob diferentes arranjos espaciais. Pesquisa Agropecuária Brasileira, v. 46, 609-616 p.
- Sindmilho & Soja. 2020.** Soja e Suas Riquezas - História. Disponível em: <<http://www.fiesp.com.br/sindmilho/sobre-o-sindmilho/curiosidades/soja-e-suas-riquezas-historia/>> Acesso em 29 agosto 2020.
- Scikit-learn. 2021.** Disponível em: < <https://scikit-learn.org/stable/> > acesso em 23 abril 2021.

Soma Brasil. Sistema de Observação e Monitoramento da Agricultura no Brasil. 2021. Disponível em < <https://mapas.cnpem.embrapa.br/somabrasil/webgis.html> > acesso em 23 de abril 2021.

Takamiya, K., T. Tsuchiya, H. Ohta. 2000. Degradation pathway(s) of chlorophyll: what has gene cloning revealed? Trends in Plant Science Volume 5, Issue 10, 426-431 p.

Tilman, D., C. Balzer, J. Hill & B.L. Befort. 2011. Global food demand and the sustainable intensification of agriculture. Proc. Natl. Acad. Sci. 108, 20260–20264. Disponível em: < <https://www.pnas.org/content/108/50/20260> > Acesso em: 23 agosto 2020.

Trevisan, R., O. Perez, N. Schimitz, B. Diers, N. Martin. 2020. High-throughput phenotyping of soybean maturity using time series uav imagery and convolutional neural networks. Remot Sens. 2020, 12, 3617.

UFRGS. Universidade Federal do Rio Grande do Sul. 2021. Disponível em < https://www.ufrgs.br/wiki-r/index.php?title=Hist%C3%B3ria_do_R > acesso em 23 de abril 2021

USDA. 2020. World Agricultural Supply and Demand Estimates. Interagency Commodity Estimates Committee Forecasts. Disponível em: <<https://apps.fas.usda.gov/psdonline/circulars/production.pdf>>. Acesso em 27 maio de 2020

Von Bueren, S.K. A. Burkat, A. Huaeni, A. Rascher, M.P. Tuohy, I.J Yule. 2015. Deploying four Option UAV-based Sensors Over Grassland: Challenges and Limitations. Biogeosciences, v.12, 163-175 p.

Watson, A. et al. 2018. Speed breeding is a powerful tool to accelerate crop research and breeding. Nat. Plants 4: 23–29. Disponível em: <<https://www.nature.com/articles/s41477-017-0083-8?proof=true>> Acesso em 24 agosto 2020.

Python. 2021. Disponível em: < <https://www.python.org/> > acesso em 23 abril 2021

Yuan, W. N.K. Wijewardane, S. Jenkins, G. Bai, Y. Ge, G.L. Graef. 2019. Early prediction of soybean traits through color and texture features of canopy rgb imagery. Nature Research (2019) 9:14089.