

LUCAS TITONELLI FERREIRA DONATO

AVALIAÇÃO REMOTA DA MATURAÇÃO DE SOJA POR IMAGENS DE *DRONES*

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Magister Scientiae*.

Orientador: Aluizio Borém de Oliveira

Coorientador: Leonardo Volpato

**VIÇOSA - MINAS GERAIS
2023**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

D677a
2023

Donato, Lucas Titonelli Ferreira, 1997-

Avaliação remota da maturação de soja por imagens de
drones / Lucas Titonelli Ferreira Donato. – Viçosa, MG, 2023.
1 dissertação eletrônica (30 f.): il. (algumas color.).

Orientador: Aluizio Borém de Oliveira.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Biologia Geral, 2023.

Referências bibliográficas: f. 26-30.

DOI: <https://doi.org/10.47328/ufvbbt.2023.190>

Modo de acesso: World Wide Web.

1. Glycine max. 2. Soja - Melhoramento genético. 3. Drone.
4. Sensoriamento remoto. 5. Melhoramento de cultivos agrícolas.
I. Oliveira, Aluizio Borém de, 1959-. II. Universidade Federal de
Viçosa. Departamento de Biologia Geral. Programa de
Pós-Graduação em Genética e Melhoramento. III. Título.

CDD 22. ed. 633.342

Bibliotecário(a) responsável: Bruna Silva CRB-6/2552

LUCAS TITONELLI FERREIRA DONATO

AVALIAÇÃO REMOTA DA MATURAÇÃO DE SOJA POR IMAGENS DE *DRONES*

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento para obtenção do título de *Magister Scientiae*.

APROVADA: 27 de fevereiro de 2023.

Assentimento:



Documento assinado digitalmente

LUCAS TITONELLI FERREIRA DONATO

Data: 18/04/2023 13:22:37-0300

Verifique em <https://validar.iti.gov.br>

Lucas Titonelli Ferreira Donato
Autor



Documento assinado digitalmente

ALUIZIO BOREM DE OLIVEIRA

Data: 19/04/2023 06:36:46-0300

Verifique em <https://validar.iti.gov.br>

Aluízio Borém de Oliveira
Orientador

*A Deus, a minha família, professores,
amigos, e todos aqueles que de alguma
forma me apoiaram e incentivaram até aqui.*

Obrigado!

AGRADECIMENTOS

A Deus, por sempre me guiar pelos melhores caminhos e escolhas.

Aos meus pais e irmãos, exemplos de pessoas, que tornaram toda minha trajetória possível, com apoio, conselhos, amor, carinho, paciência e incentivo.

À Universidade Federal de Viçosa, pelos ensinamentos, pela graduação em Agronomia, e pela oportunidade de cursar um mestrado no departamento de Genética e melhoramento.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos.

Ao meu professor e orientador, Aluizio Borém, pela amizade, paciência, pelo incentivo, por todos os conselhos, e ensinamentos pessoais e profissionais.

Ao meu coorientador, Leonardo Volpato, pela relação amigável construída, por todo conhecimento compartilhado, dicas, e pelo tempo dedicado a me guiar e auxiliar no seguinte trabalho.

Ao meu tio Sergio, grande responsável por me introduzir na pesquisa científica, e por ser um exemplo de profissional.

Aos meus amigos que tornam meus dias mais leves.

E a todos que de alguma forma contribuíram para execução desse trabalho.

Muito Obrigado!

RESUMO

DONATO, Lucas Titonelli Ferreira, M.Sc., Universidade Federal de Viçosa, fevereiro de 2023. **Avaliação remota da maturação em soja por imagens de *drones*.** Orientador: Aluizio Borém de Oliveira. Coorientador: Leonardo Volpato.

Nos programas de melhoramento de soja, uma das tarefas executadas em campo é estimar o número de dias do plantio até a maturação, no qual define-se a recomendação de uma determinada cultivar por meio dos grupos de maturação. Essa atividade demanda uma elevada mão de obra e visitas frequentes aos experimentos avaliados. Além de ser uma atividade dispendiosa, a fenotipagem humana possui uma chance considerável de erro na classificação das parcelas. Com o objetivo de melhorar a execução dessa função, este estudo buscou analisar e validar uma metodologia para avaliação remota da maturação em soja com uso de câmera RGB acopladas aos *drones* de baixo custo. Através de índices vegetativos, ambientes, modelos estatísticos e extração de pixels nas parcelas, foi possível verificar quais combinações apresentam maior correlação comparadas às realizadas por profissionais em campo. Coletou-se dados em solo de 90 parcelas em 3 ambientes para realizar comparação com o estimado pela metodologia proposta. A combinação dos índices GLI (*greenness leaf index*) e NGRDI (*normalized red green difference index*) com o modelo de regressão local não paramétrica, LOESS (*Locally estimated scatterplot smoothing*), e extração da mediana dos pixels, revelou uma forte correlação de Pearson quando comparados à maturação aferida em campo ($r = 0,84 - 0,94$ para GLI. $r = 0,81 - 0,93$ para NGRDI). Outro parâmetro que contribuiu para validação da metodologia foi o RMSE (*root-mean-square error*), que apresentou valores consideravelmente baixos (RMSE GLI = 1.24 - 1.66, RMSE NGRDI = 1.30 - 2.04). Também foi possível identificar que um dos ambientes gerou menores correlações, sendo possível associar esse menor desempenho à presença de plantas invasoras e falhas de germinação nas parcelas analisadas. Dessa forma, a metodologia se mostrou confiável, com uma boa acurácia e alta precisão, porém é necessário se atentar às condições do ambiente a nível de parcela experimental.

Palavras-chave: UAV. *Glycine max*. Sensoriamento remoto aéreo. Fenotipagem de alto rendimento. Melhoramento vegetal

ABSTRACT

DONATO, Lucas Titonelli Ferreira, M.Sc., Universidade Federal de Viçosa, February, 2023. **Remote evaluation of soybean maturation by drone images**. Adviser: Aluizio Borém de Oliveira. Co-adviser: Leonardo Volpato.

In soybean breeding programs, one of the field tasks considered labor and time consuming is estimating the number of days from planting to maturity, in which the recommendation of a certain cultivar is defined through maturation groups. This activity demands frequent visits to the trials and a considerable chance of error in plot classification. With the aim of improving the implementation of this activity, this study sought to analyze and validate a methodology for remote evaluation of soybean maturation using an RGB camera coupled to a low-cost drones. Through vegetative indices, statistical models, and extraction of pixels in the plots, it was possible to identify the best combinations that presented high correlation to those proximal estimative collected by the professionals in the field. Ground data were collected from 90 plots in 3 environments for comparison with the remote estimation. The combination of the GLI (greenness leaf index) and NGRDI (normalized red green difference index) indices with the non-parametric local regression, LOESS (Locally estimated scatterplot smoothing), and extraction of the median of the pixels, revealed a strong Person correlation Pearson when compared to the maturation measured in the field ($r = 0,84 - 0,94$ to GLI. $r = 0,81 - 0,93$ to NGRDI). Another parameter that contributed to the validation of the methodology was the RMSE (root-mean-square error), which presented considerably low values (RMSE GLI = 1.24 – 1.66, RMSE NGRDI = 1.30 – 2.04). It was also possible to identify that one of the environments expressed correlations. This may be due to the presence of weeds and germination failures in the analyzed plots. Thus, the methodology proved to be reliable, with good accuracy and high precision, but it is necessary to look at the field conditions.

Keywords: UAV. *Glycine max*. Aerial remote sensing. High-throughput phenotyping. Plant breeding

SUMÁRIO

1.	INTRODUÇÃO.....	8
2.	REVISÃO BIBLIOGRÁFICA	10
2.1	CULTURA DA SOJA	10
2.2	FENOTIPAGEM DE ALTO RENDIMENTO	11
3.	MATERIAIS E MÉTODOS	12
3.1	ÁREA EXPERIMENTAL	12
3.2	EQUIPAMENTOS, SOFTWARES E PROCESSOS	14
3.3	ESTIMAÇÃO DOS DIAS PARA MATURAÇÃO	16
3.4	VALIDAÇÃO DA METODOLOGIA.....	17
4.	RESULTADOS E DISCUSSÃO	18
5.	CONCLUSÕES.....	25
6.	REFERÊNCIAS	26
7.	MATERIAL SUPLEMENTAR	30

1. INTRODUÇÃO

A Soja é um dos principais commodities mundiais, e os seus subprodutos, óleo e farelo, são fundamentais na alimentação humana e animal. O Brasil tem papel importante na produção do grão, já que atualmente ocupa a primeira posição com 135,409 milhões de toneladas na safra 20/21, o que corresponde a cerca de 37,3% do total produzido. (Embrapa, 2021).

A produção mundial de soja geralmente está localizada em latitudes maiores que 30°LS devido as condições de clima temperado favoráveis a cultura, sendo o Brasil uma das exceções nesse cenário, visto que boa parte do nosso cultivo ocorre em regiões com latitude inferiores a 20°LS (Embrapa, 2000), com um predomínio significativo no Cerrado brasileiro (Silva et al., 2017).

No final da década de 70, a área plantada correspondente a soja no Brasil era torno de 5 milhões de hectares (Borém e Miranda, 2013), hoje, graças aos avanços do melhoramento genético e a expansão da fronteira agrícola, a área plantada corresponde a 40,8 milhões de hectares (Conab, 2022; Embrapa, 2022). O aumento da capacidade produtiva e a adaptação da cultura a regiões de menores latitudes estão diretamente relacionados aos avanços tecnológicos (Klahold et al., 2006). Esses pontos somados a precocidade dos cultivares, que diminui o tempo da cultura no campo, e consequentemente a exposição a patógenos, são as principais características exigidas pelo mercado (Teixeira, 2017).

A escolha das cultivares para cada região, deve se basear em diversas características, sendo o grupo de maturação relativa (GMR) uma das mais importantes. Antes de Alliprandini et al. (2009) realizar os estudos de GMR no Brasil, com base em um modelo dos Estados Unidos, as cultivares eram como: precoce, médio e tardio. Agora, com o GMR a nova escala varia de 0 (cultivares para regiões de grande latitude) a 10 (cultivares para regiões de pequena latitude), conforme preconiza (Embrapa, 2010).

Com a modernização da agricultura, o que chamamos de agricultura digital, ferramentas do sensoriamento remoto vêm sendo utilizadas para monitorar os campos, auxiliando nas tomadas de decisões, otimizando processos, enriquecendo a coleta de dados e melhorando a gestão dos recursos.

Nos programas de melhoramento, estamos vivendo a era 4.0, caracterizada por grandes avanços e pelos recursos da agricultura digital, que através do

sensoriamento remoto, possibilita apropriação da fenotipagem de alto rendimento, vindo do inglês, *high throughput phenotyping* (HTP), e do aprendizado de máquina, mas conhecido como *machine learning* (Vianna, 2020). O desenvolvimento de novas cultivares demanda bastante tempo e mão de obra, logo, o uso de novas ferramentas é fundamental para acelerar esse processo, e minimizar custos. Com a fenotipagem convencional, na classificação das parcelas experimentais quanto ao GMR, é necessária à coleta de dados em campo em relação ao número de dias do plantio até a maturação (DPMsolo). Especialmente para as grandes empresas, que possuem programas de melhoramento com centenas de milhares de parcelas a serem avaliadas anualmente, envolvendo muitos profissionais, a alta demanda de tempo, custo, e a possibilidade de erros nas classificações tornam-se grandes desafios.

Umas das ferramentas do sensoriamento remoto disponíveis para contornar esse problema são os VANTs (veículos aéreos não tripulados), também conhecidos como RPAS (*remotely piloted aircraft system*) ou drones. Com o avanço tecnológico, a disponibilidade de câmeras RGB mais modernas acoplados aos *drones*, permite o acesso a imagens de alta resolução por via aérea se tornando fácil e de baixo custo (Araus et al., 2018; Holman et al., 2016). O desenvolvimento de softwares, sensores, e a programação computacional permitem usufruir das imagens captadas pelos drones para estudos da fenotipagem de alto rendimento (Jorge, Inamasu, 2014).

A aplicação dessa ferramenta na determinação do DPM (dias para maturação) nos programas de melhoramento de soja, possibilita a padronização das análises, diminuindo o tempo, a chance de erros e a demanda de profissionais em campo, reduzindo custos.

A fenotipagem de alto rendimento pode ser adaptada para extrair diferentes informações, em culturas variadas (Araus et al., 2018). No caso da soja, alguns trabalhos como o de Narayanan et al. (2019) e Volpato et al. (2021) apresentaram bons resultados no uso de câmeras RGB para estimação da maturação. O trabalho de Volpato et al. (2021), que se baseou no de Narayanam et al. (2019), testou-se três índices vegetativos (GLI, TGI, HI), três ambientes no estado de Minnesota, duas frequências de voos, cinco métodos de extração da informação do pixel, dados de dois anos, e com voos realizados a uma altura de 61 m, o que permitiu uma resolução de aproximadamente 2.6 cm/pixel. Partindo disso, o presente trabalho buscou testar uma metodologia semelhante à usada no trabalho referenciado, com intuito de contribuir para evolução da mesma e avaliar a aplicabilidade com alteração de alguns

parâmetros. Dessa forma, através de uma ordem diferente na execução dos processos computacionais, buscou-se uma melhor eficiência na aplicação dos scripts, utilizando outros ambientes, em outro hemisfério, com menor latitude, dois novos índices (NGRDI e VARI) e com uma resolução alvo melhor, de aproximadamente 0.9 cm/pixel.

2. REVISÃO BIBLIOGRÁFICA

2.1 CULTURA DA SOJA

A soja [*Glycine max* (L.) Merrill], é originária do leste da Ásia e teve sua introdução no Brasil em 1882, no estado da Bahia. Porém, somente anos depois, no Rio Grande do Sul, que a cultura mostrou um bom desenvolvimento, devido as condições climáticas mais parecidas com seu local de origem, de onde as cultivares foram trazidas (Silva et al., 2022).

Na década de 30, a produção de soja começou a tomar proporções comerciais, com a primeira exportação para a Alemanha em 1938. Na segunda metade do século passado, começou a surgir o movimento de expansão da cultura rumo as regiões, de menor latitude (Sediyama et al., 2009). A partir da década de 70, quando ocorreu uma implementação de novas tecnologias na agricultura possibilitando um aumento na produtividade, a região centro-oeste passou a contribuir significativamente na produção nacional (Almeida et al., 1999), se tornando a maior região produtora do país.

Com a consolidação da soja no cerrado, nos últimos 40 anos muito avanços foram feitos pelas instituições de pesquisa, trazendo o Brasil ao topo da produção mundial de soja. Enquanto a produção aumentou sete vezes nesse período, a área correspondendo ao cultivo de soja aumentou apenas quatro vezes (Silva et al., 2022), evidenciando a maior eficiência produtiva do Brasil

A soja possui duas principais fases em seu desenvolvimento, que podem ser separadas em vegetativo (V) e reprodutivo (R) (Figura1). A identificação dentro de cada fase ocorre pela contagem de folhas, flores, vagens e do amarelecimento das folhas (Farias et al., 2007).

O processo de maturação da soja acontece nas fases R7 e R8, (Figura 1), e dura em torno de 3 semanas. As folhas começam a mudar a coloração, indo do verde claro, passando pelo amarelo, e por fim um tom amarronzado com a senescência

foliar. Elas podem ser consideradas maduras ao final desse processo, quando 95% das vagens atingem a coloração citada (Volpato et al., 2021). Do ponto de vista de bandas RGB, quando a soja inicia o processo de maturação R7 (Figura 1) o marrom se torna a cor em predominância devido ao aumento da banda vermelha, que passa a refletir mais de 30 % (Embrapa, 2010).




Figura 1 – Fases de maturação da soja

Fonte: <https://elevagro.com/conteudos/fotos/escala-fenologica-da-soja>

2.2 FENOTIPAGEM DE ALTO RENDIMENTO

A fenotipagem de alto rendimento é uma ferramenta em constante crescimento que potencializa e acelera as descobertas da genética e do melhoramento, através da integração de áreas da fitotecnia, computação e engenharia (Tanger et al., 2017; Shakoore et al., 2017).

A escolha e caracterização de fenótipos sobre condições de campo é considerado um limitante nos programas de melhoramento de plantas. Os programas de melhoramento muitas vezes necessitam de coletar dados de maturidade de soja em milhares de parcelas, com várias repetições, em diferentes ambientes, demandando visitas periódicas aos campos experimentais. Isso resulta em uma quantidade de dados muito grande, com uma logística onerosa e passível de erros (White et al., 2012). Dessa forma, o uso de ferramentas de sensoriamento remoto e da computação para análise de dados, tem se tornado mais frequente. O avanço na

aplicação da HTP está ligado com acesso a imagens de alta resolução, evolução dos sensores e o uso dos *drones* (Sankaran et al., 2015). Isso aliado aos algoritmos computacionais, possibilita o aumento da eficiência e precisão na coleta e análise de dados, melhorando a compreensão da genética e as influências ambientais (Volpato et al., 2021).

Inúmeros pesquisadores têm encontrado resultados promissores nas avaliações da fenotipagem de alto rendimento na cultura da soja (Bai et al., 2016; Yu et al., 2016; Maimaitijiang et al., 2017; Miller et al., 2018; Baek et al., 2020). Reduzindo o espectro da pesquisa ao uso de drones com imagens RGB, com o uso de índices vegetativos, Volpato et al. (2021) encontrou valores promissores de correlação para a classificação de dias para maturação da soja. Entretanto, o uso dessas ferramentas do HTP no melhoramento da soja ainda é relativamente recente, e abrange um número alto de combinações e possibilidades. O avanço constante é fundamental para entender e moldar os processos, a fim de viabilizar a prática em larga escala nos avanços genéticos.

Assim, o objetivo deste trabalho foi se basear em Volpato et al. (2021) para analisar e validar mais uma metodologia de estimação do número de dias para maturação na cultura da soja, com o uso de drones e câmeras RGB, a fim de contribuir para a aplicação da HTP em escalas cada vez maiores.

3. MATERIAIS E MÉTODOS

3.1 ÁREA EXPERIMENTAL

O experimento foi realizado no campo experimental da empresa Celeiro Sementes, que gentilmente cedeu os dados para este trabalho. Os referidos campos experimentais estão localizados ao sul do estado do Piauí (Figura 2), na zona rural do município de Monte Alegre do Piauí, coordenadas (S 9°23'28", O 45°07'58"). A Região é caracterizada pela transição entre a caatinga e o cerrado, altitude de 640 m acima do nível do mar, com pluviosidade anual média de 1000mm (Embrapa, 2004). O clima é tropical, com inverno seco e chuvas no verão.

A área experimental possui 3 ambientes nomeados como P01, P02 e P03, com 3800, 600 e 600 parcelas, respectivamente (Figura 2). O experimento na área P01 foi plantado no dia 12/12/2020 e possui algumas parcelas com duas fileiras (Tabela 1), com as demais parcelas constituídas por 4 linhas. Já os P02 e P03 possuem apenas

parcelas de 4 linhas, plantadas dias 13/12/2020 (P02) e 21/12/2020 (P03) (Tabela 1). As linhas possuíam 5 m de comprimento e 0,75 m de espaçamento entre elas e os tratos culturais demandados pela cultura foram feitos de forma uniforme pelos experimentos.

O primeiro voo foi realizado no dia 29 de janeiro de 2021, e o último no dia 9 de abril de 2021, com uma maior concentração e consequentemente menor espaçamento de voos no mês de março, época em que um número significativo de parcelas estavam atingindo a fase de maturação. Foram realizados ao todo 26 voos ao total, sendo 10 para o P01 e 8 para cada uma dos demais ambientes. As coletas dos dados de maturação convencional a nível de solo foram realizadas de forma aleatória em 90 parcelas para cada um dos ambientes.

Tabela 1 – Número de parcelas, número de voos e área de cada uma das unidades experimentais utilizadas.


Ambiente	P01	P02	P03
Nº de parcelas	3366 de 4 linhas 434 de duas linhas	600 de 4 linhas	600 de 4 linhas
Nº de voos	10	8	8
Data dos voos (2021)	Jan: 29 Fev: 11 Mar: 11, 17, 22, 24, 28, 31 Abr: 04, 08	Jan: 29 Mar: 12, 21, 25, 29 Abr: 01, 05, 09	Jan: 29 Mar: 12, 21, 25, 29 Abr: 01, 05, 09
Área (ha)	5.3	0.95	0.95



P01



P02



P03




Figura 2 – Ortomosaico das áreas experimentais P01 (17/03/21), P02 e P03 (21/03/21), com estágio fenológico de R5 a R7 e localização geográfica da região no Estado do Piauí.

3.2 EQUIPAMENTOS, SOFTWARES E PROCESSOS

O equipamento utilizado para a coleta das imagens foi um drone Dji Phantom 4 PRO v2.0 (SZ DJI Technology Co., Ltd.), com a câmera RGB CMOS 1" de 20 Megapixels nativa. Os voos tiveram horário padronizado entre as 11 e as 14 horas devido a maior luminosidade, e foram realizados a 36 metros de altura em relação ao solo. Adotou-se 75 % de sobreposição (*Overlap*) entre cada imagem, com o GSD (*ground sampling distance*) alvo de aproximadamente 0.9 cm por pixel. O drone foi configurado para voar no modo autônomo seguindo os planos de voos criados por meio de um tablet com o software Pix4Dcapture (v4.11.0; Pix4D, Prilly). A área P01 necessitou de aproximadamente 500 fotos por voo, e os demais 150 fotos por voo, para permitir completa cobertura das parcelas experimentais.

Para um controle preciso do georreferenciamento das imagens, foram distribuídos aleatoriamente no solo, placas vermelhas de 60cm x 50cm, conhecidas como *Ground Control Points* (GCPs). As posições desses pontos de controle foram determinadas posteriormente com um GPS Garmin, eTrex 30x (Garmin, Kansas, USA). O software utilizado para a construção dos ortomosaicos foi o Pix4D Mapper

(v4.5.4; Pix4D, Prilly, Suíça). As análises e processamento das imagens foram através de um *laptop* com processador de 16 núcleos AMD Ryzen 9 (AMD, California, USA) 16GB de RAM e uma placa gráfica dedicada de 6 GB NVIDIA GeForce RTX2060 Qmax (NVIDIA, California, USA). Os softwares utilizados foram o QGIS 3.28.2 (QGIS Development Team) e o R (Development R Core Team).

As marcações das *plots* para a extração dos pixels dentro dos ortomosaicos foram feitas através dos *grids* em formato *shapefile*. Eles possuem formato retangular e foram posicionados no centro, abrangendo cerca de 50 % da área da parcela a fim de evitar influência das plantas vizinhas. Através do software R, após a segmentação dos *plots*, calculou-se os índices vegetativos, sendo eles, GLI (*green leaf index*) (Louhaichi et al., 2001), HI (*primary colours hue index*) (Richardson et al., 2009), NDRDI (*Normalized green red difference index*) (Tucker et al., 1975), TGI (*The triangular greenness index*) (Hunt et al., 2013) e VARI (*Visible Atmospherically Resistant Index*) (McKinnon et al., 2017). Três desses índices foram utilizados por Volpato et al. (2021). Os outros dois, NGRDI e VARI, foram utilizados com outros fins de HTP em Zhou et al. (2018), Fernandez-Gallego et al. (2019), Vianna (2020), e testados no presente trabalho para estimação da DPM. A extração dos valores na escala dos índices vegetativos foi feita pelo valor da média (*mean*) e pelo valor da mediana (*median*) dos valores calculados em cada índice e presentes nos pixels dentro dos *shapefiles*. Os pacotes '*raster*' (Hijmans et al., 2020), '*FIELDimageR*' (Matias, et al., 2020) e '*rgdal*' (Bivand et al., 2020) no R foram utilizados para este processo (Figura 3).

Para a determinação do momento da maturação, o valor do *threshold*, padronizado em 0.06, com exceção do índice VARI, que devido a valores de maior escala, optou-se por usar 157.




Figura 3. Demonstração de alguns processos, em ordem, da esquerda para direita, e de cima para baixo, sendo; coleta de imagens, construção dos ortomosaicos, aplicação dos shapefiles, corte das parcelas e aplicação dos índices vegetativos.

3.3 ESTIMAÇÃO DOS DIAS PARA MATURAÇÃO

Baseado em Volpato et al. (2021), dois modelos foram usados para a estimação da maturação da soja. A regressão local não paramétrica, LOESS (*Locally estimated scatterplot smoothing*) e a regressão linear segmentada do inglês, *Segmented linear regression*, também conhecida como *piecewise* (SEG). O LOESS usa uma janela de dados e se baseia em um algoritmo do dado vizinho mais próximo para construir uma curva com suavização através de uma sequência de regressões geradas em pequenos intervalos, de forma que os pontos próximos têm mais influência na função ajustada do que os pontos distantes, sendo uma ótima opção para lidar com dados ruidosos ou outliers (Marquetti., 2009). O SEG é um método de modelagem de dados

que utiliza o princípio da segmentação nos breakpoints, criando intervalos na variável x , onde ocorre uma mudança na linha de regressão, gerando 3 curvas no caso de 2 breakpoints. É uma técnica muito útil para relações que não apresentam linearidade em toda faixa de valores, possibilitando diferentes retas para cada segmento. (Pilgrim, 2021). A estimação pelos dois métodos foi feita através de um segundo script no R e os pacotes ‘stats’ e ‘segmented’ (Muggeo, 2019).

3.4 VALIDAÇÃO DA METODOLOGIA

Para analisar e validar o estudo, uma análise estatística de correlação foi realizada entre os dados de maturação coletados em campo, DPMsolo, e os dados estimados, DPMdrone. Para tal, utilizou-se o JMP software analysis (JMP® Trial 17.0, SAS Institute Inc., Cary, NC, 1989–2007).

A verificação e exclusão dos *outliers* foi feita através do *quantile range outliers* (*tail quantile* = 0.1 e $Q = 3$), com menor sensibilidade, de maneira individual para os dados de solo e para os dados de drone, de forma que não interferisse no desempenho das metodologias, visto que foram coletadas apenas 90 parcelas para validação em cada ambiente. Para os dados de campo, não precisamos realizar qualquer exclusão, porém isso não indica que eles possuam alta acurácia, visto que são dependes do operador (variam entre operadores e conforme sua fadiga), das datas de coleta. Para os dados gerados obtidos de forma remota, via *drone*, algumas poucas parcelas foram excluídas (Tabela 2).

Tabela 2. Porcentagem de *outliers* excluídos em cada ambiente.

Ambiente/Índice vegetativo	GLI	HI	NGRDI	TGI	VARI
P01	2,2%	2,2%	0%	12,2%	1,1%
P02	11,1%	10%	2,2%	4,4%	4,4%
P03	4,4%	1,1%	6,6%	5,5%	5,5%


Utilizou-se o coeficiente de correlação de Pearson (r), para cada um dos conjuntos, calculou-se o coeficiente de determinação (R^2), e o *root-mean-square error*

(RMSE) a fim de analisar qual deles se aproxima mais com as estimativas de maturação baseadas em dados coletados em solo, podendo assim ser validado.


4. RESULTADOS E DISCUSSÃO

Após a coleta dos dados e as análises realizadas, considerando cinco índices vegetativos, dois métodos estatísticos para extração do valor numérico de cada índice no pixel, e dois modelos para estimar o número de dias para a maturação obteve-se um total de 20 valores de estimação de dias para a maturação (DPMdrone) em cada parcela. Os dados foram cruzados de forma que possibilitaram analisar o desempenho das combinações em relação ao DPMsolo separadamente. Entretanto houve uma priorização nas variáveis analisadas, a fim de facilitar a classificação de quais conjuntos trouxeram melhores resultados. A ordem seguida foi: índice vegetativo, metodologia e extração dos pixels.

P01



P02



P03




Figura 4. Correlação entre os dados coletados em campo (DPMsolo), e os dados estimados via imagens (DPMdrone) contendo os 5 índices RGB (GLI, HI, NGRDI, TGI, VARI), as duas metodologias (LOESS, SEG) e as duas extrações de pixels (MD = median, ME = mean) para os três ambientes, P01, P02, P03.

O coeficiente de correlação de Pearson (r) serve para mostrar se existe relação entre duas variáveis, e como essa relação pode ser classificada. Caso ela exista,

podemos interpretá-la como negativa ou positiva, e em termos de grandeza, sendo: $r = 0,10$ até $0,30$ (fraco); $r = 0,40$ até $0,6$ (moderado); $r = 0,70$ até 1 (forte) (Dancey e Reidy 2005). Partindo dessa consideração, e seguindo a ordem de prioridade citada, é possível observar que quanto ao índice vegetativo obtivemos uma melhor correlação (r) para GLI = $0.73 - 0.80 - 0.86 - 0.88$ (P01), $0.84 - 0.84 - 0.93 - 0.94$ (P02), $0.56 - 0.55 - 0.77 - 0.84$ (P03) e NGRDI = $0.86 - 0.81 - 0.63 - 0.87$ (P01), $0.80 - 0.76 - 0.93 - 0.91$ (P02), $0.78 - 0.77 - 0.71 - 0.83$ (P03) (Figura 4 e Tabela S1). Apesar dos valores gerais obtidos para GLI serem majoritariamente menores quando comparados com os reportados em LOESS e SEG, *mean* e *median* por Volpato et al. (2021), eles podem ser considerados fortes por estarem acima de $r = 0,70$ (Figura 4). A proximidade no desempenho entre esses dois índices também pode ser observada como relata Vianna (2020), onde apesar de não terem atingido valores tão altos de correlação com o DPM, tiveram um valor significativo quando correlacionados. O NGRDI se mostrou eficiente em se relacionar com a cor verde na soja, como pode ser visto em Zhou et al. (2018) para estimação da clorofila, e no presente trabalho, para maturação. No trabalho de Vianna (2020), os índices GLI e NGRDI também apresentaram resultados semelhantes entre si, mas com baixos valores de correlação para DPM.



Para o ambiente P03, os valores de correlação no índice GLI foram ligeiramente menores, $0.56 - 0.55 - 0.77 - 0.84$ (Figura 4), se comparado com os outros dois ambientes, principalmente na metodologia SEG. Isso provavelmente se deve ao fato de uma maior presença de plantas daninhas, e falhas de plantio ou germinação que afetaram o valor do índice vegetativo real, graças a presença ou a falta do verde nas parcelas. Essas interferências, quando em escalas menores, não foram consideradas outliers devido à baixa sensibilidade escolhida e condições do experimento.

Os demais índices, apesar de apresentarem combinações que expressaram um alto valor de (r), como por exemplo a HI LOESS no P01 = $0.77 - 0.85$ (Figura 4 e Tabela S1), não tiveram valores ou padrões satisfatórios nos três ambientes avaliados, o que sugere que eles não foram úteis para os objetivos de se estimar a maturação em soja nestas condições. Partindo disso, nossos resultados divergiram do observado em Volpato et al. (2021), que encontrou valores de correlação melhores para HI e TGI. Houve divergência também para o índice VARI, que não apresentou os resultados esperados, e ficou bem distante do desempenho encontrado no NGRDI, ao contrário

do que relata Fernandez-Gallego et al. (2019) e Vianna (2020), onde VARI e NGRDI tiveram resultado parecidos, mas para fins diferentes do tratado nesse trabalho.

Em relação à metodologia para estimação de dias, dentro dos índices que obtiveram melhor desempenho, os gráficos nos indicam que o LOESS, $r = 0.86 - 0.88/ 0.63 - 0.87$ (P01), $- 0.93 - 0.94/ 0.93 - 0.91$ (P02), $0.77 - 0.84/ 0.71 - 0.83$ (P03) para GLI/ NGRDI, apresentou, na maioria das vezes, uma correlação mais alta, porém próxima, a do SEG, $r = 0.73 - 0.80/ 0.86 - 0.81$ (P01), $0.84 - 0.84/ 0.80 - 0.76$ (P02), $0.56 - 0.55/ 0.78 - 0.77$ (P03). A única exceção significativa foi para NGRDI no ambiente P01, em que o LOESS_ME teve um valor de (r) significativamente menor ($r = 0.63$) que os demais para o mesmo índice e ambiente. Entretanto, como o LOESS é uma regressão local, ele precisa de voos que peguem do início ao fim do processo de maturação de todas as parcelas. Ou seja, caso os voos não sejam realizados até as últimas parcelas atingirem maturação plena (R8), a metodologia SEG pode ser adotada (Volpato et al, 2021).

Na avaliação da extração dos pixels considerando todos os índices, não foi possível observar um ganho significativo e reproduzível de maneira a formar um padrão. Quando reduzimos a análises aos índices com melhor desempenho, a combinação LOESS_MD, GLI - NGRDI, $r = 0.88 - 0.87$ (P01), $r = 0.94 - 0.91$ (P02) e $r = 0.84 - 0.83$ (P03), apresentou resultados mais constantes. Uma razão para isso é que a mediana é uma medida com tendência ao valor central, ou seja, sofre menos interferência de pixels com valores extremos causados por alguma anormalidade na parcela. Isso pode ser confirmado analisando a diferença do LOESS_MD para o LOESS_ME no ambiente P03, local onde houve uma maior presença de daninhas, falhas de germinação e acamamento, fatores que prejudicam as estimativas por meio remoto (Figura 4). Portanto, os resultados avaliados e discutidos em seguida, irão se referir a essa combinação citada, LOESS *median* para os índices escolhidos, GLI e NGRDI.

P01**P02**

P03




Figura 5. *Root mean square error (RMSE)*, coeficiente de determinação (R^2) entre a mensuração em campo no eixo Y (DPMsolo) e aos dados estimados no eixo X (DPMdrone) para GLI (esquerda) e NGRDI (direita), metodologia LOESS e extração *median* (MD) nos ambientes P01, P02, P03, (cima para baixo) respectivamente.

Como os dados acima se referem a uma seleção de melhor desempenho, os valores do coeficiente de determinação R^2 podem ser considerados bons, pois a variação nos 3 ambientes foi de $R^2 = 0,71 - 0,89$ para GLI e $R^2 = 0,69 - 0,83$ para NGRDI (Figura 5, Figura S1). Como esperado, a área P03, que sofreu mais com problemas na cultura, apresentou resultados abaixo dos demais, assim como foi visto nas outras análises. Se considerarmos os dois ambientes mais uniformes, os valores do R^2 ficam ainda melhores, $R^2 = 0,74 - 0,89$ para GLI e $R^2 = 0,76 - 0,83$ para NGRDI nos ambientes P01 e P02 respectivamente, demonstrando que a metodologia é confiável (Figura 5). O R^2 é o valor da correlação (r) elevada ao quadrado, então a classificação dos resultados esperados se assemelha muito com o que foi visto na correlação de Pearson.

Outro parâmetro importante para averiguar a acurácia dos dados estimados, é a raiz do erro quadrático médio, do inglês, *Root Mean Squared Error*, o RMSE. Nesse caso, como é uma medida que expressa o erro médio do modelo preditivo, quanto menor for o valor, melhor (Chai et al., 2014). Sendo assim, podemos interpretar os valores apresentados como bons, sendo que o maior deles foi 2.04, um valor ainda

considerado pequeno (Figura 5). O Índice GLI apresentou resultados melhores para o P01 e P02. Para o P03 o NGRDI ficou com 1.55 ante 1.66, uma diferença pouco significativa, já que estamos falando de número de dias.

É interessante observar, que apesar de valores de correlação menores quando comparado a Volpato et al. (2021), o RMSE dos dados apresentados neste trabalho foi um pouco melhor. Porém como o tamanho da amostra de dados de campo entre os dois trabalhos foi diferente, não é possível fazer nenhuma previsão quanta a diferença dos valores observados nos dois trabalhos.

Para os índices TGI, HI, VARI, mesmo não tendo performedo bem na correlação (r), os valores do RMSE, na maioria das combinações foram aceitáveis (Figura S1). Isso pode significar que o DPMdrone desses dados não seguiu a mesma tendência de variação dos valores de DPMsolo nas parcelas, mas ficaram de certa forma próximos em valores absolutos dos números de dias para maturação.

As estimativas calculadas nos mostram que quando comparado as informações de campo desse experimento, a combinação de dados escolhida, LOESS *median* para GLI e NGRDI, possui uma boa estimacão, precisão e acurácia. Os valores de RMSE aferidos confirmam que é possível validar a metodologia. É interessante considerar que a coleta em campo é suscetível a erros e divergência de avaliações, o que pode afetar a um pouco como os dois conjuntos de dados se correlacionam, interferindo negativamente no valor de (r) (Vianna, 2020; Volpato, 2021).

Do ponto de vista da fenotipagem de alto rendimento, apesar da metodologia ter se mostrado eficaz, o experimento, os dados coletados, voos, fotos e processamento dos ortomosaicos, merecem atenção na execução, tanto para experimentos futuros, quanto para aplicação do modelo estudado. Ao analisar o desempenho do P03, vimos que uma maior incidência de plantas daninhas, falha de plantio e germinação, o que afeta negativamente o desempenho do modelo. Para as estimativas de solo pode ser interessante, em caso de novos experimentos, coletar dados do maior número de parcelas, a fim de enriquecer a comparação para o modelo predito.

Na parte computacional, apesar da aplicabilidade do software R para os processos utilizados, e da disponibilidade de pacotes como '*FIELDimageR*' (Matias, et al., 2020), e *scripts open-source*, o programa demandou muito poder de processamento de hardware e necessitou de aproximadamente 60 horas para execução do *looping* de segmentação das parcelas e aplicação dos índices. Isso afeta

um pouco a aplicação dessa e de outras metodologias, sendo interessante testá-las no Python em pesquisas futuras, visto que é um software que além da CPU, utiliza também a GPU, acelerando o processamento.

5. CONCLUSÕES

A metodologia apresentada se mostrou confiável e com boa acurácia, confirmando que é possível realizar fenotipagem de alto rendimento na cultura da soja para se estimar a maturação, com câmera de baixo custo. Os índices GLI e NGRDI, a regressão LOESS e a extração do valor da mediana dos pixels se mostraram superiores as demais alternativas avaliadas.

Por outro lado, a presença de plantas daninhas, falhas nas parcelas, e a possibilidade de erros humanos na fenotipagem convencional podem resultar em baixas correlações entre as estimativas em solo, e aquelas de forma remota, via *drone*.

6. REFERÊNCIAS

ALLIPRANDINI, L.F.; ABATTI C.; BERTAGNOLLI P.F.; CAVASSIM, J.E.; GABE, H.L.; KUREK, A.; MATSUMOTO GABE, H.L.; KUREK, A.; MATSUMOTO, M.N.; DE OLIVEIRA, M.A.R.; PITOL, C.; PRADO, L.C.; STECKLIN, C. Understanding soybean maturity groups in Brazil: environment cultivar classification and stability. **Crop Science** 49,801–808, 2009.

ALMEIDA, L. A. DE.; KIIHL, R. D. S.; MIRANDA, M. A. C. DE.; & CAMPELO, G. D. A. Melhoramento da soja para regiões de baixas latitudes. **Recursos Genéticos e Melhoramento de Plantas para o Nordeste Brasileiro**, 1999.

ARAUS, J.L.; KEFAUVER, S. C.; ZAMAN-ALLAH, M.; OSLEN, M. S.; CAIRNS, J. E. "Translating high-throughput phenotyping into genetic gain." **Trends in plant science** 23.5: 451-466. 2018.

BAEK, J.; LEE, E.; KIM, N.; KIM, S.L.; CHOI, I.; JI, H.; CHUNG, Y.S.; CHOI, M.S.; MOON, J.K.; KIM, K.H. High throughput phenotyping for various traits on soybean seeds using image analysis. **Sensors**, v. 20, n. 1, p. 1–9, 2020.

BAI, G.; GE, Y.; HUSSAIN, W.; BAENZIGER, P.S.; GRAEF, G. A multi-sensor system for high throughput field phenotyping in soybean and wheat breeding. *Comput. Electron. Agric.* 128: 181–192, 2016

BIVANDB, R.; KEITT, T.; ROWLINGSON, B. (Package 'rgdal' R. <https://cran.r-project.org/web/packages/rgdal/index.html> (2020)

BORÉM, A.; MIRANDA, G. V. **Melhoramento de plantas**. 6. ed. Viçosa: UFV, 2013. 37 p.

BRAGA, C.C.; MELO, M.L.D.; MELO, E.C.S. Análise de Agrupamento Aplicada a Distribuição da Precipitação no Estado da Bahia. 10º Congresso Brasileiro de Meteorologia. Brasília-DF. Anais... Sociedade Brasileira de Meteorologia. p.1857-62, 1998.

Chai, T.; DRAXLER, R.R. "Root mean square error (RMSE) or mean absolute error (MAE). Arguments against avoiding RMSE in the literature." **Geoscientific model development** 7, no. 3 (2014): 1247-1250.

CONAB - Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: grãos, terceiro levantamento, Dezembro 2022**. Brasília: CONAB, 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos>.

EMBRAPA – Cultivares de soja, 2010. Disponível em < <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/898048/1/FolhetoSoja201011MGfinalcapa.pdf>. > Acesso em 20 de fevereiro de 2022.

EMBRAPA – Soja em números (safra 20/21) disponível em: <https://www.embrapa.br/soja/cultivos/soja1/dados-economicos#:~:text=Soja%20em%20n%C3%BAmeros%20%28safra%202019%2F20%29%20Soja%20no%20mundo.,plantada%3A%2036%2C950%20milh%C3%B5es%20de%20hectares.%20Produtividade%3A%203.379%20kg%2Fha>. Acesso em 5 de abril de 2022.

ESRI, E. "Shapefile technical description." An ESRI white paper (1998).

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. **Ecofisiologia da Soja**. Londrina: Embrapa CNPSO, 2007. 9p. (Circular Técnica, No48).

FIGUEREDO FILHO, D.B.; SILVA JUNIOR, J.A. "Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r)." **Revista Política Hoje** 18.1: 115-146. 2009.

HIJMANS, R. J. Package 'raster' R. <https://cran.r-project.org/web/packages/raster/raster.pdf> 2020.

HUNT Jr, E.R.; DORAISWAMY, P.C.; MCMURTREY, J.E.; DAUGHTRY, C.S.; PERRY, E.M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International journal of applied earth observation and Geoinformation**, 21, pp.103-112. 2013.

JORGE, L. A. C.; INAMASU, R. Y. **Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão**. Brasília: Embrapa, 2014.

KLAHOLD, C.A. Resposta da soja (*Glycine max* (L.) Merrill) à ação de bioestimulante. **Acta Scientiarum. Agronomy**, 2006.

KLINK, C. A.; MACHADO, R. B. Conservation of the brazilian cerrado. **Conservation Biology**, v.19, n.3, p.707-713, 2005.

LOUHAICHI, M.; BORMAN, M.M.; JOHNSON, D.E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**. Mar 1;16(1):65-70. 2001.

MAIMAITIJIANG, M.; GHULAM, A.; SIDIKE, P.; HARTLING, S.; MAIMAITIYIMING, M.; PETERSON, K.; SHAVERS, E.; FISHMAN, J.; PETERSON, J.; KANEDAM, S.; BURKEN, J. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 134, p. 43–58, 2017.

MAKANZA, R.; ZAMAN-ALLAH, M.; CAIRNS, J.E.; MAGOROKOSHO, C.; TAREKEGN, A.; OSLEN, M.; PASANNA, B.M High-throughput phenotyping of canopy cover and senescence in maize field trials using aerial digital canopy imaging. **Remote Sensing**, v. 10, n. 2, 2018.

MARQUETTI, A.; VIALI, L. PRINCÍPIOS E APLICAÇÕES DE REGRESSÃO LOCAL. *Análise Econômica*, [S. l.], v. 22, n. 42, 2009. DOI: 10.22456/2176-5456.10808. Disponível em: <https://seer.ufrgs.br/index.php/AnaliseEconomica/article/view/10808>. Acesso em: 24 jan. 2023.

MATIAS, F. I.; CARAZA-HARTER, M. V.; ENDELMAN, J. B. FIELDImageR: An R package to analyze ortho mosaic images from agricultural field trials. **The Plant Phenome Journal**, 3, e20005; 2020.

MCKINNOM, T.; HOFF, P. Comparing RGB-based vegetation indices with NDVI for drone based agricultural sensing. **Agribotix. Com**, 21(17), pp.1-8. 2017.

MILLER, J. J.; SCHEPERS, J.S.; SHAPIRO, C.A.; ARNESON, N.J.; ESKRIDGE, K.M.; OLIVEIRA, M.C.; GIESLER, L.J. Characterizing soybean vigor and productivity using multiple crop canopy sensor readings. **Field Crops Research**, v. 216, n. November 2017, p. 22–31, 2018.

NARAYANAM, B.; FLOYD, B.; TU, K.; RIES, L.; HAUSMANN, N. "Improving soybean breeding using UAS measurements of physiological maturity." In *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping IV*, vol. 11008, pp. 227-240. SPIE, 2019.

PILGRIM, C. Piecewise regression (aka segmented regression) in Python. **Journal of Open Source Software**, 6(68), 3859 2021

QUEIROZ, D.DE.; VALENTE, D.S.M.; PINTO, F.A.C.; BORÉM, A. 2º eds. **Agricultura digital**. Oficina de Textos, 2022

RICHARDSON, A. D.; JENKINS, J. P.; BRASWELL, B. H.; HOLLINGER, D. Y.; OLLINGER, S. V. "Near-surface remote sensing of spatial and temporal variation in canopy phenology." **Ecological Applications**, 19(6). 2009

SEDIYAMA, T.; TEXEIRA, R. C.; BARROS, H.B. Origem, evolução e importância econômica. In: SEDIYAMA, T (Ed.). **tecnologias de produção e usos da soja**, PR: Mecenass, 2009 p.1-5

SANKARAN, S.; KHOT, L.R.; ESPINOZA, C.Z.; JAROLMASJED, S.; SATHUVALLI, V.R.; VANDEMARK, G.J.; MIKLAS, P.N.; CARTER, A.H.; PUMPHREY, M.O.; KNOWLES, N.R.; PAVEK, M.J. Low-altitude, high-resolution aerial imaging systems

for row and field crop phenotyping: A review. **European Journal of Agronomy**, 70, pp.112-123, 2015.

SILVA, F.C.S.; SEDIYAMA, 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.; SEDIYAMA, T.; LUDKE, W. (Eds). **Melhoramento da Soja**. UFV, Viçosa, 2017.

SILVA, F.; BORÉM, A.; SEDIYAMA, T.; CÂMARA, G. **Soja: do plantio a colheita**. 2ª edição, São Paulo, oficina de textos, 2022.

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.

TUCKER, C.J.; ELGIN Jr, J.H.; MC MURTREY LII, J.E.; FAN, C.J. Monitoring corn and soybean crop development with hand-held radiometer spectral data. **Remote Sensing of Environment**, 8(3), pp.237-248. 1979

VIANNA, MS. Evaluation of vegetation indices from aerial images in soybean breeding. 2020. Dissertação (Mestrado em Genética e Melhoramento de Plantas) - Escola Superior de Agricultura Luiz de Queiroz, University of São Paulo, Piracicaba, 2020.

VOLPATO, L.; PINTO, F.; GONZÁLEZ-PÉREZ, L.; THOMPSON, I. G.; BORÉM, A.; REYNOLDS, M.; RODRIGUES JR, F. A. High throughput field phenotyping for plant height using UAV-based RGB imagery in wheat breeding lines: Feasibility and validation. **Front. Plant Sci.** 2021, 12, 185.

VOLPATO, L.; DOBBELS, A.; BORÉM, A.; LORENZ, A. J. Optimization of temporal UAS-based imagery analysis to estimate plant maturity date for soybean breeding. **Plant Phenome J.** 2021; e20018.

WHITE, J.W.; ANDRADE-SANCHEZ, P.; GORE, M.A.; BRONSON, K.F.; COFFELT, T.A.; CONLEY, M.M.; FELDMAN, K.A.; FRENCH, A.N.; HEUN, J.T.; HUNSAKER, D.J.; JENKS, M.A. Field-based phenomics for plant genetics research. **Field Crops Research**, v. 133, p. 101–112, 2012.

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

YU, N.; LI, L.; SCHMITZ, N.; TIAN, L.F.; GREENBERG, J.A.; DIERS, B.W. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle-based platform. **Remote Sens. Environ.** 187: 91–101. 2016

ZHOU, J.; CHEN, H.; ZHOU, J.; FU, X.; YE, H.; NGUYEN, H. T. Development of an automated phenotyping platform for quantifying soybean dynamic responses to salinity stress in greenhouse environment. **Computers and Electronics in Agriculture**, 151, 319-330, 2018

7. MATERIAL SUPLEMENTAR

		P01			P02			P03		
		<i>r</i>	R ²	RMSE	<i>r</i>	R ²	RMSE	<i>r</i>	R ²	RMSE
GLI	LOESS_ME	0.86	0.73	1.37	0.93	0.86	1.66	0.77	0.59	1.98
GLI	LOESS_MD	0.88	0.77	1.26	0.94	0.89	1.53	0.84	0.71	1.66
GLI	SEG_ME	0.73	0.53	1.75	0.84	0.71	2.44	0.56	0.31	2.56
GLI	SEG_MD	0.8	0.64	1.59	0.84	0.71	2.42	0.55	0.3	2.57
HI	LOESS_ME	0.77	0.6	1.55	0.63	0.4	3.72	0.26	0.07	2.71
HI	LOESS_MD	0.85	0.71	1.31	0.57	0.32	3.97	0.33	0.11	2.65
HI	SEG_ME	0.21	0.05	2.39	0.08	0.01	4.8	-0.39	0.16	2.58
HI	SEG_MD	-0.01	0	2.44	0.1	0.01	4.79	-0.34	0.12	2.64
NGRDI	LOESS_ME	0.63	0.4	2.06	0.93	0.87	1.81	0.71	0.51	1.95
NGRDI	LOESS_MD	0.87	0.76	1.3	0.91	0.83	2.04	0.83	0.69	1.55
NGRDI	SEG_ME	0.86	0.74	1.35	0.8	0.64	2.94	0.78	0.61	1.73
NGRDI	SEG_MD	0.81	0.66	1.55	0.76	0.58	3.2	0.77	0.59	1.78
TGI	LOESS_ME	-0.03	0	2.62	-0.35	0.12	4.75	-0.08	0.01	2.82
TGI	LOESS_MD	0.72	0.51	1.97	0.39	0.15	4.67	0.72	0.51	1.98
TGI	SEG_ME	-0.13	0.02	2.63	-0.28	0.08	4.87	-0.01	0	2.8
TGI	SEG_MD	0.12	0.02	2.63	-0.13	0.02	5.02	-0.13	0.02	2.8
VARI	LOESS_ME	0.06	0	2.66	0.18	0.03	4.84	-0.15	0.02	2.78
VARI	LOESS_MD	0.01	0	2.66	0.36	0.13	4.59	-0.05	0	2.81
VARI	SEG_ME	-0.11	0.01	2.65	0.4	0.16	4.51	0.27	0.08	2.75
VARI	SEG_MD	0.02	0	2.66	0.29	0.09	4.71	0.22	0.05	2.72

Figura S1. Parâmetros estatísticos de todas as combinações, nos 3 ambientes.