

EMBRAPA GADO DE CORTE

---

Mapeamento Sistemático de  
Estudos sobre Fenotipagem com a  
Utilização de Drones

---

*Autora*  
Viktória Serra de Lima  
MORAES

*Supervisor*  
Camilo CARROMEU

Campo Grande, MS  
10 de Setembro de 2018

# Conteúdo

1	Motivação.....	5
1.1	Metodologia .....	5
2	Planejamento.....	5
3	Processo de Pesquisa .....	7
4	Extração de Dados .....	8
4.1	Estudo SCD1 .....	12
4.2	Estudo SCD2 .....	13
4.3	Estudo SCD3 .....	13
4.4	Estudo SCD4 .....	14
4.5	Estudo SCD5 .....	15
4.6	Estudo SCD6 .....	15
4.7	Estudo SCD7 .....	16
4.8	Estudo SCD8 .....	17
4.9	Estudo EIC1.....	17
4.10	Estudo EIC2.....	18
4.11	Estudo EIC3.....	18
4.12	Estudo EIC4.....	19
4.13	Estudo EIC5.....	20
4.14	Estudo IEEE1 .....	21
4.15	Estudo SCO1 .....	21
4.16	Estudo SCO2 .....	22
4.17	Estudo SCD9 .....	23
4.18	Estudo SCD10 .....	24
4.19	Estudo SCD11 .....	24

	3
4.20 Estudo EIC6.....	25
4.21 Estudo EIC7.....	26
4.22 Estudo IIEEE2 .....	28
4.23 Estudo IIEEE3 .....	29
4.24 Estudo IIEEE4 .....	29
4.25 Estudo SCO3 .....	31
4.26 Estudo SCO4 .....	31
4.27 Estudo SCO5 .....	33
4.28 Estudo SCO6 .....	34
4.29 Estudo SCO7 .....	35
4.30 Estudo SCD12 .....	36
4.31 Estudo SCD13 .....	37
4.32 Estudo SCD14 .....	38
4.33 Estudo EIC8.....	39
4.34 Estudo SCO8 .....	43
4.35 Estudo SCO9 .....	44
4.36 Estudo SCO10 .....	45
4.37 Estudo SCO11 .....	46
4.38 Estudo SCD15 .....	47
4.39 Estudo SCD16 .....	49
4.40 Estudo SCD17 .....	51
5 Comparação com o Estudo Proposto .....	52
6 Documentação da Revisão .....	52
Referências .....	53

## RESUMO

Neste trabalho, é apresentado um mapeamento sistemático de estudos sobre melhoramento de culturas e pecuária de precisão cuja metodologia envolva o uso de veículos aéreos não tripulados (VANTs).

São propostas palavras-chave a fim de construir uma *query* de busca e obter trabalhos relevantes na área provindos de fontes de pesquisa virtuais. Tal relevância é validada, então, a partir de certos critérios estabelecidos com esse propósito e que, após aplicados, filtram consideravelmente a quantidade e a qualidade dos estudos em questão, com o intuito de que os mesmos se adequem ao objetivo buscado. Finalmente, são extraídos os dados de interesse de cada um dos trabalhos selecionados e, assim, a revisão pode ser formalmente documentada e disseminada.

O intuito principal desse mapeamento é fornecer um compêndio de estudos para que pesquisadores e melhoristas possam ter rápido acesso às informações buscadas.

**Palavras-Chave:** Veículo Aéreo não Tripulado (VANT); Drone; Agropecuária; Plantação; Fenótipo; Pecuária de Precisão; Melhoramento de Culturas.

## 1 Motivação

A necessidade da condução de um mapeamento sistemático da bibliografia, considerando a área de fenotipagem com a utilização de veículos aéreos não tripulados (VANTs), ocorre uma vez que os estudos sobre tal assunto se mostram consideravelmente recentes e, assim, os pesquisadores e profissionais cuja área de atuação envolve essa atividade necessitam de auxílio literário a fim de melhor conduzir experimentos.

A fenotipagem realizada manualmente, como acontece atualmente, consiste em um trabalho oneroso e repetitivo, levando a longas jornadas de trabalho. Com isso, a precisão é fortemente prejudicada, especialmente ao final das jornadas, graças ao cansaço e geral imprecisão humana.

Esse mapeamento representa a fase inicial de um trabalho que busca, ao final, gerar um método que ambos melhoristas e produtores agropecuários possam utilizar com o intuito de avaliar e aprimorar suas plantações, gerando, possivelmente, um produto comercial.

### 1.1 Metodologia

A metodologia utilizada para a realização desse mapeamento sistemático é proposta por Barbara Kitchenham[1] e tem como objetivo resumir as evidências existentes; identificar eventuais lacunas na literatura atual a fim de sugerir áreas para futuras investigações; e fornecer um contexto para posicionar adequadamente novas atividades de pesquisa.

No caso desse trabalho, são buscados parâmetros de voo para o drone que será utilizado, e os resultados obtidos anteriormente na literatura com a finalidade de obter um guia para o trabalho a ser realizado.

## 2 Planejamento

Tendo em vista o objetivo apresentado, surgem algumas questões a serem respondidas pelos trabalhos buscados, formalmente referidas como questões de pesquisa:

1. Quais estudos apresentam pesquisas na área agropecuária?
2. Dentre esses, quais abordam a fenotipagem das plantas cultivadas?
3. Finalmente, quais se utilizam de drones?

Com essas questões em mente, construiu-se, então, uma *query* baseada nas *strings* presentes na tabela 2.1. Essas *strings* buscam ser o mais genéricas possíveis, a fim de gerar bons resultados, porém específicas o suficiente para que atendam as questões propostas.

Tal que:

- **UAV**: Unmanned Aerial Vehicle (veículo aéreo não tripulado);
- **UAS**: Unmanned Aerial System (sistema aéreo não tripulado);

**Tabela 2.1.** Termos utilizados para construção da *query*

<b>Agropecuária</b>	<b>Fenótipo</b>	<b>Drone</b>
AGRICULTURE, FARM, PLANTATION, LIVESTOCK	PHENOTYPE, PHENOTYPING, CROP BREEDING, FORAGE BREE- DING, PHENOMICS	DRONE, DRONES, UAV, RPA, RPAS, UAS

- **RPA:** Remotely Piloted Aircraft (aeronave pilotada remotamente);
- **RPAS:** Remotely Piloted Aircraft System (sistema de aeronaves pilotadas remotamente).

Com a aplicação de proposições lógicas, a *query* final pode ser dada por:

(AGRICULTURE or FARM or PLANTATION or LIVESTOCK) and  
(PHENOTYPE or PHENOTYPING or PHENOMICS or "CROP BREEDING" or "FORAGE BREEDING") and  
(DRONE or DRONES or UAV or RPAS or RPA or UAS)

São definidos, ainda, critérios que contemplam as questões propostas e servem como métricas de inclusão para os estudos a serem avaliados (CI); assim como critérios para a exclusão dos mesmos (CE), de forma que esses sejam classificados como relevantes ou não.

**Tabela 2.2.** Critérios de inclusão (CI) da busca de mapeamento sistemático

<b>CI1</b>	Coleta de dados de plantações por drones.
<b>CI2</b>	Coleta de dados de plantações por imagens.
<b>CI3</b>	Informações quanto a fenotipagem de plantas cultivadas.

**Tabela 2.3.** Critérios de exclusão (CE) da busca de mapeamento sistemático

<b>CE1</b>	Não contemple os critérios de inclusão.
<b>CE2</b>	Não esteja em português, inglês ou espanhol.
<b>CE3</b>	Esteja incompleto, indisponível ou já tenha sido incluído.
<b>CE4</b>	Tenha sido publicado antes de 2006.
<b>CE5</b>	Não tenha sido publicado em anais de eventos ou revistas, como capítulos de livros.

### 3 Processo de Pesquisa

Para a realização da busca, foram utilizadas fontes de pesquisa digitais com grande acervo e que são fortemente reconhecidas pela comunidade científica. São elas: ACM (*ACM Digital Library*), Scopus, EI Compendex (*Engineering Village*), IEEE (*IEEE Xplore Digital Library*), SciELO, Web of Science e Science Direct/Elsevier (DYBAet al. 2007). Essas bases podem ser vistas elencadas na tabela 3.1.

**Tabela 3.1.** Fontes de pesquisa utilizadas na busca de estudos primários

Fonte de Pesquisa	URL
Scopus	<a href="https://www.scopus.com/">https://www.scopus.com/</a>
ScienceDirect	<a href="https://www.sciencedirect.com/">https://www.sciencedirect.com/</a>
IEEE Xplore Digital Library	<a href="https://ieeexplore.ieee.org/">https://ieeexplore.ieee.org/</a>
ACM Digital Library	<a href="https://dl.acm.org/">https://dl.acm.org/</a>
EI Compendex	<a href="https://www.engineeringvillage.com/">https://www.engineeringvillage.com/</a>
SciELO	<a href="http://www.scielo.org">http://www.scielo.org</a>

Para realizar a busca nas bases citadas, foi utilizada a *query* proposta na seção 2. Após sua aplicação, foram retornados 496 resultados, como pode ser observado na tabela 3.2. Com a *query* em questão, a base de dados Scopus retornou 40 resultados; a ScienceDirect, 357; a IEEE retornou 6; a EI Compendex obteve 92 resultados; a ACM, por sua vez, retornou apenas 1 resultado; e a SciELO não mostrou estudo algum.

**Tabela 3.2.** Resultados das buscas

Sigla	Fonte de Busca	Resultados
SCO	Scopus	40
SCD	ScienceDirect	357
IEEE	IEEE Xplore Digital Library	6
ACM	ACM Digital Library	1
EIC	EI Compendex	92
SCI	SciELO	0

Como o número de resultados retornados foi elevado e não há a possibilidade ou mesmo a necessidade da revisão de todos os estudos obtidos, foram aplicados os critérios de exclusão a fim de refinar a busca e obter resultados mais condizentes com o objetivo desejado. Disso consiste a fase de seleção dos estudos.

Os 496 estudos obtidos foram avaliados quanto aos critérios de inclusão, idioma, ano de publicação, meio de publicação, estado de inclusão e disponibilidade.

Assim, após a aplicação de CE1, CE2, CE3, CE4 e CE5, todos os estudos obtidos contemplam os critérios de inclusão, ou seja, tratam de coleta de dados de fenotipagem de plantações obtidos por imagens provenientes de drones. O total de resultados, assim, diminuiu para 40 estudos selecionados, como pode ser observado na tabela 3.3.

**Tabela 3.3.** Resultados após a seleção de estudos

Base	Resultados	CE1	CE2	CE3	CE4	CE5	Total
SCO	40	-4	-2	-17	0	-4	11
SCD	357	-115	0	-1	-133	-91	17
IEEE	6	-2	0	0	0	0	4
ACM	1	-1	0	0	0	0	0
EIC	92	-21	-7	-51	0	-5	8
SCI	0	0	0	0	0	0	0

Os estudos selecionados foram, então, adicionados a uma ferramenta de gerenciamento de referências para facilitar a sua visualização (Mendeley[2]). A necessidade do conteúdo essencial para a extração de dados pôde ser considerada, enfim, satisfeita.

## 4 Extração de Dados

A extração de dados consiste na obtenção de informações a partir dos estudos selecionados (listados nas tabelas 4.1, 4.2, 4.3 e 4.4). Para tal, foi elaborado, primeiramente, o formulário de extração de dados 4.1 a fim de extrair as informações básicas dos estudos. A seguir, foi gerado o formulário 4.2, com o intuito de filtrar e registrar informações técnicas provindas de cada um dos estudos em questão.

**Formulário 4.1.** Formulário básico de extração de dados

1. Título;
2. Ano de publicação;
3. Objetivos;
4. Relevância (extrema, alta, média e baixa);
5. Resultados.

É importante ressaltar que o formulário 4.2 é apenas um ponto de partida para a busca de informações e que nem todos os estudos são capazes de emitir todos os dados ali enumerados. A altura de voo, no entanto, é um dos fatores mais

**Tabela 4.1.** Estudos selecionados do ano de 2018

<b>Identificador</b>	<b>Título</b>	<b>Ano</b>
SCD1	Assessing yield and fertilizer response in heterogeneous smallholder fields with UAVs and satellites	2018
SCD2	Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring	2018
SCD3	Detecting newly grown tree leaves from unmanned-aerial-vehicle images using hyperspectral target detection techniques	2018
SCD4	Estimation of plant height using a high throughput phenotyping platform based on unmanned aerial vehicle and self-calibration: Example for sorghum breeding	2018
SCD5	High-throughput field phenotyping in dry bean using small unmanned aerial vehicle based multispectral imagery	2018
SCD6	Improved estimation of leaf area index and leaf chlorophyll content of a potato crop using multi-angle spectral data – potential of unmanned aerial vehicle imagery	2018
SCD7	Multitemporal field-based plant height estimation using 3D point clouds generated from small unmanned aerial systems high-resolution imagery	2018
SCD8	Multi-temporal high-resolution imaging spectroscopy with hyperspectral 2D imagers – From theory to application	2018
EIC1	Comparison of segmentation methods on images of energy plants obtained by UAVs	2018
EIC2	Time-Series Multispectral Indices from Unmanned Aerial Vehicle Imagery Reveal Senescence Rate in Bread Wheat	2018
EIC3	Estimation of Vegetable Crop Parameter by Multi-temporal UAV-Borne Images	2018
EIC4	Extracting leaf area index using viewing geometry effects—A new perspective on high-resolution unmanned aerial system photography	2018
EIC5	Quantitative Estimation of Wheat Phenotyping Traits Using Ground and Aerial Imagery	2018
IEEE1	Locating Crop Plant Centers From UAV-Based RGB Imagery	2018
SCO1	Phenotyping Conservation Agriculture Management Effects on Ground and Aerial Remote Sensing Assessments of Maize Hybrids Performance in Zimbabwe	2018
SCO2	Unmanned aerial system assisted framework for the selection of high yielding cotton genotypes	2018

**Tabela 4.2.** Estudos selecionados do ano de 2017

<b>Identificador</b>	<b>Título</b>	<b>Ano</b>
SCD9	Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle	2017
SCD10	Exploring Robots and UAVs as Phenotyping Tools in Plant Breeding	2017
SCD11	Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery	2017
EIC6	Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine	2017
EIC7	Super-Resolution of Plant Disease Images for the Acceleration of Image-based Phenotyping and Vigor Diagnosis in Agriculture	2017
IEEE2	Plant Leaf Segmentation for Estimating Phenotypic Traits	2017
IEEE3	Improving Orthorectification of UAV-Based Push-Broom Scanner Imagery Using Derived Orthophotos From Frame Cameras	2017
IEEE4	Prediction of Sorghum Biomass Based on Image Based Features Derived from Time Series of UAV Images	2017
SCO3	The DOM Generation and Precise Radiometric Calibration of a UAV-Mounted Miniature Snapshot Hyperspectral Imager	2017
SCO4	UAV Localization in Row Crops	2017
SCO5	Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution	2017
SCO6	Digital Counts of Maize Plants by Unmanned Aerial Vehicles (UAVs)	2017
SCO7	High Throughput Phenotyping of Blueberry Bush Morphological Traits Using Unmanned Aerial Systems	2017

**Tabela 4.3.** Estudos selecionados do ano de 2016

<b>Identificador</b>	<b>Título</b>	<b>Ano</b>
SCD12	Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle	2016
SCD13	Evaluation of ground, proximal and aerial remote sensing technologies for crop stress monitoring	2016
SCD14	Machine Learning for High-Throughput Stress Phenotyping in Plants	2016
EIC8	Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform	2016
SCO8	Automated Ortho-Rectification of UAV-Based Hyperspectral Data over an Agricultural Field Using Frame RGB Imagery	2016
SCO9	Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries	2016
SCO10	Unmanned Aerial Vehicles for High- Throughput Phenotyping and Agronomic Research	2016
SCO11	High Throughput Field Phenotyping of Wheat Plant Height and Growth Rate in Field Plot Trials Using UAV Based Remote Sensing	2016

**Tabela 4.4.** Estudos selecionados dos anos anteriores a 2016

<b>Identificador</b>	<b>Título</b>	<b>Ano</b>
SCD15	Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review	2015
SCD16	Field-based crop phenotyping: Multispectral aerial imaging for evaluation of winter wheat emergence and spring stand	2015
SCD17	Green area index from an unmanned aerial system over wheat and rapeseed crops	2014

**Formulário 4.2.** Formulário técnico de extração de dados

1. Região e bioma nos quais o estudo foi realizado;
2. Altura de voo do *VANT*;
3. Ângulo da câmera utilizada;
4. Modelo e tipo da câmera utilizada;
5. Distância de amostra de solo (GSD).

importantes, pois afeta a velocidade máxima de voo para manter a sobreposição de imagens, a resolução e a duração do voo. A distância de amostra de solo (GSD), por sua vez, é relacionada a essa altura e, quanto maior seu valor, menor é a resolução espacial e, assim, menor a quantidade de detalhes visíveis na imagem.

#### 4.1 Estudo SCD1

**Relevância:** Média

O estudo SCD1, intitulado "Assessing yield and fertilizer response in heterogeneous smallholder fields with UAVs and satellites"[3], de 2018, tem por objetivo testar imagens obtidas de VANTs e avaliar se essas podem ser usadas para aferir interceptação de luz e rendimento de colheitas em campos de pequenos produtores, assim como respostas aos fertilizantes naquela região.

SCD1 foi realizado na região da África subsariana, contando, assim, com uma grande diversidade de condições ambientais. Para a realização do estudo, foi utilizado o VANT *eBee* da empresa *SenseFly*, em conjunto com uma câmera *Canon S110 NIR* com filtros verde, vermelho e infravermelho próximo (NIR).

As imagens foram coletadas a cada quinze dias entre as dez horas da manhã e o meio-dia, com o *eBee* voando a 286 m acima do nível do solo e resultando em tamanhos de pixel de aproximadamente  $10 \times 10$  cm. Para o processamento das imagens resultantes, foi utilizado o software de imagem *CAN-EYE*. A obtenção dos resultados encontrou algumas limitações, tais como sobreposição espectral nas bandas vermelha e verde e grande banda passante ( $0.1 \mu\text{m}$  à meia altura).

O *eBeePVI* está fortemente relacionado à cobertura do solo com um valor de  $R^2$  de 0.85. Em teoria, quando o *eBeePVI* é zero, a cobertura do solo também deve ser zero. No entanto, a interceptação da relação é negativa, indicando que alguns pixels do solo também podem ser encontrados entre 0 e 0.053. O *eBeePVI* se mostrou menos sensível à variação quando comparado ao NDVI via satélite, mais notavelmente a valores de NDVI acima de 0.6, onde mosaicos *eBee* sempre apresentam valores de CV muito mais altos do que as imagens de satélite, pois o campo de visão instantâneo do *eBee* é muito menor e resulta em um maior número de valores contribuintes por parcela. Essa resolução espacial mais alta elucidada as plantas individuais ausentes nas linhas e as lacunas menores nas copas das plantas que não são visíveis nas imagens do *WorldView-2*.

As estimativas de interceptação de luz procedentes dos mosaicos referentes ao VANT foram significativamente correlacionadas com o rendimento das colheitas; e o índice de vegetação perpendicular (PVI) obtido do eBee se mostrou fortemente relacionado à cobertura do solo e interceptação de luz pela safra.

## 4.2 Estudo SCD2

**Relevância:** Baixa

O estudo SCD2, intitulado "Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring"[4], de 2018, busca avaliar os índices vegetativos (VIs) tradicionais quanto a importância para estimativa de biomassa de milho; e estabelecer e avaliar modelos baseados na combinação de variáveis agro-climáticas, evapotranspiração referência e os índices propostos.

Foi executado na região da Tarazona de La Mancha (Albacete, Espanha), com características agronômicas relativamente uniformes e é classificada como semi-árida. SCD2 utilizou o quadricóptero md4-200 da empresa **Microdrones, Inc.**, munido de uma câmera **PENTAX A40 RGB** com lente de zoom integrada. O sensor foi um CCD  $7.2 \times 5.4$  mm, com 12 milhões pixels e tamanho de pixel  $1.8 \times 1.8 \mu\text{m}$ . O tamanho da imagem foi de  $4000 \times 3000$  e a largura focal de 7.9 mm. A fim de obter uma resolução de  $1.03 \text{ cm pixel}^{-1}$ , voos foram realizados a 48 m de altura.

Vergara-Díaz et al.[5] analisou diferentes condições de adubação nitrogenada do milho comparando VIs derivados de imagens RGB (ao nível do solo) e imagens NDVI obtidas de um VANT na fase de floração. Este autor concluiu que o NDVI permaneceu praticamente inalterado de 4.000 a 13.000 kg ha<sup>-1</sup>, o que corresponde a um dossel denso (IAF > 4). As relações obtidas entre os índices levam a conclusão de que a inclusão de informações agroclimáticas junto com VIs melhora a estimativa de TDB; os melhores índices para obter esses relacionamentos foram GLI e VARI; e mais pesquisas devem ser realizadas para desenvolver procedimentos padronizados de fácil aplicação para obter valores radiométricos mais precisos com câmeras de baixo custo montadas em VANTs de baixo custo.

## 4.3 Estudo SCD3

**Relevância:** Baixa

O estudo SCD3, intitulado "Detecting newly grown tree leaves from unmanned-aerial-vehicle images using hyperspectral target detection techniques"[6], de 2018, procura investigar a possibilidade de se detectar nova folhagem de bitmaps de VANTs com espectro limitado usando técnicas hiperespectrais de detecção de alvos, as performances de técnicas ativas e passivas de detecção de alvos, e a possibilidade de uma detecção bem-sucedida de nova folhagem usando imagens de sensoriamento remoto em escala de decímetro.

SCD3 foi efetuado o sul do Taiwan, utilizando um drone **eBee RTK** da empresa **SenseFly** e uma câmera **Canon PowerShot S110**. Os ortomosaicos foram gerados a partir de imagens com  $4000 \times 3000$  pixels de resolução com o software de pós-processamento **Postflight Terra 3D**.

Na área A, ocorreu de o alvo específico ser amostrado do centro de um cluster de novos pixels de folhagem e houve a ocorrência de uma contaminação rara causada por pixels adjacentes. Embora as imagens a nível de decímetro tenham sido derivadas usando uma técnica de média de blocos de  $5 \times$  ou  $10 \times$  pixels, as assinaturas resultantes apareceram ligeiramente deslocadas da imagem de resolução centimétrica original. A amostragem na área B exibiu um padrão de assinatura quase idêntico ao da área A.

Por vezes, os alvos podem acabar por ser misturados com outros materiais, alguns dos quais podem estar embutidos em um espaço de sub-pixel, visto que seu tamanho é claramente menor que a resolução de pixels; por exemplo, a detecção de folhagem usando imagens de satélite. Neste caso, os alvos só podem ser detectados a nível de sub-pixel. Ao diferenciar novos pixels de folhagem de folhas maduras, grama, solo e materiais de concreto sobre florestas, a detecção de alvos pôde ser alcançada com uma precisão geral de mais de 90%. À medida que novas folhas são introduzidas no lado inferior de um dossel de alta densidade, o sombreamento das folhas das árvores causará algumas dificuldades na recuperação de novas folhas com um sensor RGB-VANT.

#### 4.4 Estudo SCD4

##### **Relevância:** Média

O estudo SCD4, intitulado "Estimation of plant height using a high throughput phenotyping platform based on unmanned aerial vehicle and self-calibration: Example for sorghum breeding"[7], de 2018, tem como objetivo estimar a altura de uma criação de teste de sorgo usando fenotipagem de larga escala em uma plataforma de VANT.

SCD4 ocorreu em Hermitage, Queensland, Australia. O estudo fez uso do drone **X8**, da empresa **Skywalker Technology Co.**. Planos de voo autônomo foram construídos utilizando o software **Mission Planner**, com altura de voo de 20 m e velocidade de 3 m/s. A câmera utilizada foi a **Sony DSC-RX100M3** com  $5472 \times 3648$  pixels. O tamanho do pixel foi de aproximadamente 0.45 cm.

O método da nuvem de pontos pressupõe que o nível do solo é visível em uma parcela e/ou ao redor do campo a partir do ar, sendo adequado apenas para copa com menor cobertura do solo e/ou onde há grandes lacunas entre as parcelas. A principal alternativa para uma análise de nuvem de pontos de um único voo é usar uma referência onde uma pesquisa de drone foi realizada no mesmo campo sem culturas (antes da emergência ou após a colheita) para representar o nível do solo de todo o campo.

O erro total foi de 19% para a população reprodutora de sorgo e é aceitável nas gerações iniciais, uma vez que um número maior de candidatos será selecio-

nado pelos melhoristas e essas linhas devem ser identificadas em fases posteriores da seleção.

O método resultou em uma precisão razoável e pode ser potencialmente estendida a outras características em fenotipagem de larga escala através da fusão de dados medidos manualmente e obtidos por VANTs, o que é um ótimo compromisso entre precisão de estimativa, tempo de medição manual e investimento para estimar a altura do dossel com precisão.

#### 4.5 Estudo SCD5

**Relevância:** Baixa

O estudo SCD5, intitulado "High-throughput field phenotyping in dry bean using small unmanned aerial vehicle based multispectral imagery"[8], de 2018, propõe a validação de imagens multi-espectrais providas de VANTs para a fenotipagem em grande escala de testes de reprodução de feijão seco através de diversos ambientes e estações.

O estudo foi realizado em múltiplas localidades em Washington, EUA. O veículo utilizado foi o octocóptero HiSystems GmbH com o controlador de transmissor de rádio MX20 Hott. A plataforma foi integrada com a câmera multi-espectral XNiteCanon SX230 NDVI. Os voos foram realizados a 120 m acima do nível do solo e o GSD para imagens termais foi de aproximadamente  $10.4 \text{ cm pixel}^{-1}$ .

Em geral, a área média do GNDVI e do dossel a 45 DAP e a média do GNDVI a 60 DAP foram as mais correlacionadas ( $r > 0.73$ ) com o rendimento de sementes. Ademais, os recursos derivados de dados de sensoriamento remoto foram comparados entre si através de painéis a fim de determinar a inter-relação temporalmente, ou seja, em diferentes estágios de crescimento; e todas as correlações foram significativas com  $P < 0.0001$ .

Para testes de estresse hídrico, SCD5 obteve imagens com forte e significativa correlação com variáveis de resposta. No entanto, testes de estresse de nitrogênio mostraram baixa correlação entre os dados obtidos a partir das imagens e as variáveis obtidas a partir da referência terrestre. Finalmente, dados de temperatura se mostraram altamente correlacionados com o rendimento de sementes e classificação de biomassa.

#### 4.6 Estudo SCD6

**Relevância:** Baixa

O intuito do estudo SCD6, intitulado "Improved estimation of leaf area index and leaf chlorophyll content of a potato crop using multi-angle spectral data – potential of unmanned aerial vehicle imagery"[9], de 2018, é estudar o potencial das medidas multi-angulares coletadas por VANTs para a obtenção do índice de área foliar (IAF) e tabela de cores foliares pela inversão do model PROSAIL.

Realizado em um campo de batatas na fronteira entre a Holanda e a Bélgica, SCD6 utiliza uma câmera multi-espectral da empresa *Rikola Ltd.* acoplada a um octocóptero *Altura AT8*. As imagens coletadas são de  $1010 \times 1010$  pixels. A câmera possui um campo de visão horizontal e vertical de  $36.5^\circ$ . O drone foi programado para voar a 120 m do solo, a uma velocidade de 4 m/s. Após a georreferência, as imagens foram exportadas com tamanho de pixel de 5 m.

Foi observado que quanto mais e melhor-distribuídos ângulos, mais precisos os resultados. Em geral, a inversão baseada em dados de nadir[10] e baseada em dados angulares produziram resultados muito semelhantes. As diferenças entre o nadir IAF e o IAF invertido multi-angular foram geralmente pequenas (diferença média de  $-0.05 \pm 0.43$ ). Quando apenas o espectro de reflectância medido na posição nadir foi utilizado para a inversão, o IAF foi obtido com um RMSE de 0.7 e para a linha de regressão foi obtido um  $R^2$  de 0.91.

No geral, a inversão do PROSAIL produziu bons resultados para a recuperação do IAF, mas resultados ruins para a recuperação do teor de clorofila foliar.

#### 4.7 Estudo SCD7

##### Relevância: Média

O estudo SCD7, intitulado "Multitemporal field-based plant height estimation using 3D point clouds generated from small unmanned aerial systems high-resolution imagery"[11], de 2018, busca avaliar técnicas de estrutura de movimento baseadas em sistemas aéreos não-tripulados para modelar colheitas em 3D repetidamente e consistentemente; desenvolver e aplicar um fluxo de trabalho de processamento replicável para obter altura de plantas ao longo do tempo; e investigar a precisão de estimativas de altura de plantas via estrutura de movimento quando comparadas a medidas de campo.

SCD7 foi conduzido na fazenda de pesquisa da universidade do Texas, EUA. O estudo utilizou um drone *Phantom 3 Pro* da empresa DJI, com a câmera da própria aeronave e o software de pilotagem automática *Pix4Dcapture*. Os voos foram realizados a uma altitude de 20 m e sobreposição de imagem de 90%. A câmera foi configurada de modo a ter uma resolução de 12 megapixels e largura focal de 20. O GSD obtido variou entre 0.81 e 0.88, dependendo do voo.

A geração multi-temporal de dados de altura das plantas provou a capacidade de sistemas aéreos não-tripulados para a coleção de dados necessários em programas de melhoramento de plantas. Uma distância média da amostra do solo (GSD) de 0.85 cm foi alcançada para mosaicos com densidades de nuvens de pontos de mais de 2000 pontos/ $m^2$ . O erro de geolocalização (raiz quadrada média RMS) dos dados gerados, calculados usando as localizações iniciais e reconstruídas do ponto de controle do solo, variou de 1.5 a 4 cm com o tempo e foi considerado razoável e aceitável devido ao erro do ponto de controle no solo ( $< 10$  cm) e os tamanhos das parcelas. No entanto, vale ressaltar que as precisões de geologia listadas são um tanto subjetivas, já que pontos de verificação de controle de solo independentes não foram usados.

#### 4.8 Estudo SCD8

**Relevância:** Baixa

O estudo SCD8, intitulado "Multi-temporal high-resolution imaging spectroscopy with hyperspectral 2D imagers – From theory to application"[12], de 2018, investiga o fluxo de trabalho de espectroscopia de imagem com imagens 2D.

O trabalho foi realizado em Rheinbach, Alemanha. Foi utilizado a câmera instantânea hiperespectral UHD 185-Firefly em um gimbal MK HiSight SLR2 e um drone não mencionado no artigo. Os voos foram realizados a 30 m acima do solo e as imagens geradas possuem resolução de  $50 \times 50$  pixels.

Em comparação com observações sem imagens, onde apenas um número limitado de medições pode ser realizado, centenas de pixels são capturados de uma inspeção ótica automatizada. O campo de visão específico (SFOV) define a composição dos pixels e suas propriedades que são usadas para caracterizar um AOI. O campo de visão (FOV) da UHD é composto pelos FOVs individuais de cada pixel. Quando o UHD é aplicado em um drone, a pegada aumenta conforme a altitude de voo aumenta. Simultaneamente, a área de interesse é coberta por uma parte menor do FOV e, conseqüentemente, a SFOV também muda. Os resultados mostram, ainda, que os dados de imagem e não imagem não são intrinsecamente comparáveis.

#### 4.9 Estudo EIC1

**Relevância:** Baixa

O estudo EIC1, intitulado "Comparison of segmentation methods on images of energy plants obtained by UAVs"[13], de 2018, tem como objetivo encontrar o melhor algoritmo de segmentação com o propósito de segmentar a floresta energética onde híbridos da mesma espécie estão presentes. A finalidade é encontrar um método que seja tanto eficiente quanto robusto no sentido de não ser fortemente dependente dos parâmetros de entrada.

Efetuada em Kompolt, Hungria, EIC1 utilizou um quadricóptero Phantom 2 da empresa DJI. A câmera foi uma GoPro Hero4 com um sensor CMOS de 12.1 megapixel e resolução de  $4000 \times 3000$ . O voo ocorreu a 60 m acima do alvo e velocidade de 5 m/s.

Foi usado o processo de segmentação semi-automático do eCognition para criar o melhor resultado de segmentação possível pelos métodos do estado da arte implementados neste pacote de software. É uma abordagem supervisionada que possui muitos parâmetros de entrada e requer interação do usuário na seleção de regiões que precisam de segmentação adicional.

A utilização das imagens obtidas pelo drone e o processo de segmentação eCognition resultaram em uma precisão de 74,85% ao operar em imagens contendo diversos híbridos, tarefa difícil até mesmo para o olho humano. O método de MSS da Orfeo ToolBox, no entanto, atingiu apenas 43,02%. A implementação

do Matlab do algoritmo MSS foi o método insensível a parâmetros que atingiu a maior precisão com 66.12%.

#### 4.10 Estudo EIC2

**Relevância:** Média

O estudo EIC2, intitulado "Time-Series Multispectral Indices from Unmanned Aerial Vehicle Imagery Reveal Senescence Rate in Bread Wheat"[14], de 2018, visa avaliar as associações entre os índices de vegetação espectral (SVI) derivados do VANT e traços fisiológicos medidos por instrumentos de mão; prever a taxa de senescência de SVIs baseados em drones, bem como seu impacto em características relacionadas ao rendimento; e avaliar a diversidade de germoplasma de trigo para taxa de senescência sob dois tratamentos de irrigação.

EIC2 foi realizado em algumas cidades no norte da China. O projeto utilizou uma câmera multi-espectral *Sequoia 4.0* acoplada a um drone *DJI Inspire-1 T600*. A *Sequoia 4.0* obteve imagens com resolução de  $1280 \times 960$  pixels. A distância média de amostragem do solo foi entre 2.5 e 2.8 para voos entre 30 e 40 m de altitude, respectivamente.

Fortes correlações foram detectadas entre SVIs e características fisiológicas medidas no solo em ambas as análises de regressão ( $R^2 = 0.69$  a  $0.78$ ) e correlações de Pearson ( $r = 0.55$  a  $0.78$ ) no enchimento médio a tardio de grãos, enquanto houve correlações negativas significativas ( $-0.43$  a  $-0.76$ ) entre SVI e temperatura de dossel. Correlações negativas a positivas ( $r = -0.17$  a  $0.17$ ) entre SVIs baseadas em VANT e medições de clorofila usando sensores portáteis provavelmente foram graças a erros de observação durante a aquisição de dados baseados em terra. O erro, por sua vez, pode ser devido ao fato de que as observações baseadas no solo são baseadas em 5 a 10 plantas, enquanto as SVIs derivadas de drone eram representativas de toda a unidade experimental.

Esses resultados mostraram que SVIs derivadas de VANT forneceram valores fenotípicos mais precisos com custo muito menor e menos tempo, em comparação com os dados coletados por dispositivos portáteis. Assim, a dinâmica de crescimento das culturas pode ser prevista a partir das diferenças de SVI em ambientes contrastantes.

Cinco índices vegetativos espectrais mensurados utilizando uma plataforma VANT mostraram as vantagens de velocidade e precisão sobre ferramentas de base terrestre. Um rápido declínio nesses índices, no entanto, foi observado do enchimento de grãos tardios sob irrigação limitada, mostrando altas taxas de senescência com impacto negativo nas características relacionadas ao rendimento.

#### 4.11 Estudo EIC3

**Relevância:** Alta

O estudo EIC3, intitulado "Estimation of Vegetable Crop Parameter by Multi-temporal UAV-Borne Images"[15], de 2018, tem como objetivo aferir a

aplicabilidade de imagens RGB transmitidas por VANTs para capturar informações sobre a altura das colheitas de três vegetais (berinjela, tomate e repolho) durante toda a temporada de cultivo.

Conduzido em Bengaluru, Índia, EIC3 contou com um drone DJI 3 Professional e uma câmera padrão DJI FC300X com largura focal de 3.61 mm. As imagens obtidas possuem resolução de 4000×3000 pixels e a altitude de voo foi estabelecida para 20 m, com oscilações de 17 m a 24 m devido a variações no GPS do próprio VANT. Devido a tais variações, a resolução média do solo flutuou entre 6 e 8 mm por pixel.

Os resultados indicam que uma estimativa bem-sucedida da altura de culturas para hortaliças com formas de crescimento muito diferentes pode ser alcançada (com valor de  $R^2$  variando de 0.89 para tomate a 0.97 para repolho). O experimento mostra que as imagens obtidas dos VANTs, em combinação com técnicas de estrutura de movimento, podem ser usadas para estimar a altura da cultura de legumes durante todo o período de crescimento.

Métodos modernos de aprendizado de máquina podem manipular variáveis altamente inter-relacionadas melhor que modelos de regressão de mínimos quadrados ordinários e, portanto, devem ser a ferramenta de escolha para a previsão da altura de culturas baseada em múltiplas métricas de altura de cultura de imagens RGB suportadas por drones. Os resultados não mostraram uma superioridade clara de regressão de floresta aleatória (RFR) sobre regressão de suporte vetorial (SVR), embora a RFR sempre produzisse resultados ligeiramente melhores, que pode ser explicado pela menor sensibilidade à assimetria de dados.

Valores de altura da cultura obtidos por drones indicam um desvio sistemático dos medidos em campo, indicando uma superestimativa crescente da altura da cultura vegetal pelo modelo de predição. Como a data de amostragem foi a mesma para ambos, essa divergência não pode ser atribuída a diferenças de tempo entre as medições. Embora as precisões dos modelos de previsão de biomassa com base na altura estimada sejam semelhantes à biomassa prevista com base na altura medida da cultura, cerca de 10% da variação nos valores de biomassa permaneceu inexplicada.

#### 4.12 Estudo EIC4

**Relevância:** Média

O estudo EIC4, intitulado "Extracting leaf area index using viewing geometry effects — A new perspective on high-resolution unmanned aerial system photography"[16], de 2018, foca na melhoria de medições com a visualização de informações de geometria ao combinar medições de refletância não calibradas (pelo uso de fotografias RGB).

O estudo foi realizado em Eschikon-Lindau, Suíça, contando com um solo cambissolo rico em esqueletos com 21% de argila, 21% de silte e 3.5% de matéria orgânica, e um pH de 6.7. O drone utilizado foi um GreenCopter Imager-Quadro DualCam da empresa RUCON Engineering baseado em uma configuração Mikrokopter (HiSystems). O VANT foi operado em modo piloto automático com o

software `Mikrokoopter tool 2.14e`, com altura de 30 m acima do solo e velocidade de 3 m/s. A câmera `Sony RX100 II` foi operada com uma resolução de  $5472 \times 3648$  pixels e largura focal de 10.4 mm.

EIC4 mostra que a visualização de estimativas de LAI de geometria com base em imagens RGB não calibradas representa um substituto válido para medições de validação de solo na plantação de soja. O processamento de imagens oblíquas originais evita a necessidade de orto-retificação e geração de ortomosaico e, portanto, permite processar cenas complexas, como campos de agricultura.

Com base em uma verificação manual de cem imagens de plotagem selecionadas aleatoriamente por campanha, nenhuma imagem precisou ser excluída. Portanto, assumiu-se uma segmentação válida para as imagens restantes.

O georreferenciamento neste estudo gerou erros de referência de até 0.09 m com desvios padrão de até 0.06 m, podendo ser considerado apropriado para amostras de  $1 \times 3$  m.

#### 4.13 Estudo EIC5

**Relevância:** Baixa

O estudo EIC5, intitulado "Quantitative Estimation of Wheat Phenotyping Traits Using Ground and Aerial Imagery"[17], de 2018, proporciona uma comparação entre a performance de dois métodos de obtenção de imagem — via plataforma terrestre móvel (PTM) e veículo aéreo não tripulado (VANT). Essa comparação é realizada por meio de uma estimativa quantitativa de características de fenotipagem do trigo em um ensaio de campo.

EIC5 foi executado em Mallala, no sul da Austrália. O sistema de imagens com VANT contou com um quadricóptero `3DR Solo` da empresa `3D Robotics Inc.`, uma câmera digital compacta `Sony RX100 III` com resolução de 20.1 megapixels, e o software de planejamento de voo `Mission Planner (ArduPilot)`. Os voos foram realizados a uma altitude de 30 m, que resultou em uma sobreposição de imagens de mais de 80%. O processamento das imagens foi dado, ainda, pelo software de fotogrametria `Pix4Dmapper v4.0`.

As estimativas de altura do dossel de imagens do PTM tiveram um melhor ajuste geral (RMSE = 3.95 cm,  $R^2 = 0.94$ ) com medidas manuais, em comparação com estimativas derivadas de imagens do VANT (RMSE = 6.64 cm,  $R^2 = 0.85$ ). Porém, em contraste com a situação com estimativas de altura, os modelos de regressão linear associados às estimativas de vigor do dossel por imagem de drone tiveram uma concordância ligeiramente melhor com as medições de referência (RMSE = 0.057,  $R^2 = 0.57$ ) do que as estimativas baseadas em imagens de PTM (RMSE = 0.063,  $R^2 = 0.42$ ).

As imagens de traços a partir de drones quase não contêm informações tão detalhadas quanto as imagens de traços providas de PTM. No entanto, eles ainda são capazes de fornecer estimativa global razoável de traços da informação ruidosa, mas completa.

A obtenção de imagens por PTM mostrou melhores estimativas de altura usando imagens de alta resolução da cobertura vegetal, enquanto as imagens por

VANT fornecem melhores estimativas do vigor dessa cobertura. O uso de VANTs é um meio rápido e eficiente de cobrir uma grande área de terra em um curto espaço de tempo e é suficientemente preciso para a estimativa de características a nível de cobertura vegetal. A utilização de PTMs, por sua vez, é capaz de capturar estruturas detalhadas de folhagem com alto nível de fidelidade.

#### 4.14 Estudo IEEE1

##### **Relevância:** Média

O estudo IEEE1, intitulado "Locating Crop Plant Centers From UAV-Based RGB Imagery"[18], de 2018, descreve a estimativa do centro de sorgo vegetal a partir de imagens de VANTs. É utilizado o Aprendizado de Múltipla Instância.

IEEE1 não menciona o drone ou a câmera utilizados. Tampouco menciona a região de coleta das imagens. As imagens foram obtidas a uma altitude de 40 m e velocidade de 8 m/s. A resolução é de 0.59 cm/pixel.

Os resultados mostram que o método funciona melhor quando as plantas apresentam baixa densidade foliar e a limitação do uso de características simples para descrever diversas plantas de sorgo; e obtiveram uma precisão geral média de 66%, e um recall de 64%.

Como plantas têm diferentes números de folhas em várias orientações, uma combinação de características simples pode não ser suficiente para descrever plantas de sorgo heterogêneas; além disso, os dados de treinamento negativos podem ter rótulos falsos devido a erro humano durante a rotulagem. Centros de plantas podem ser facilmente perdidos durante a rotulagem, e acidentalmente podem ser usados como dados negativos de treinamento.

#### 4.15 Estudo SCO1

##### **Relevância:** Média

O estudo SCO1, intitulado "Phenotyping Conservation Agriculture Management Effects on Ground and Aerial Remote Sensing Assessments of Maize Hybrids Performance in Zimbabwe"[19], de 2018, buscou avaliar a eficiência de um conjunto de índices de sensoriamento remoto ao aferir as diferenças de rendimento de diferentes híbridos de milho em fases iniciais de crescimento em condições convencionais de lavoura (CL) e plantio direto (CD).

Baseado em Harare, Zimbabwe, o projeto utilizou um drone *OktoXL 6S12* da empresa *Mikrokopter* e dois tipos de voos foram realizados — um com uma câmera digital RGB *Panasonic Lumix GX7*, e outro com, simultaneamente, uma câmera multi-espectral *Tetracam micro-MCA* e uma termal *TEAX Thermal Capture*. As imagens RGB utilizaram uma lente de 20 mm e tamanho do sensor de  $17.3 \times 13.0$ , com resolução de  $4592 \times 3448$  pixels. As imagens multi-espectrais foram alinhadas e calibradas para reflectância usando o *PixelWrench II* versão 1.2.2.2.

A média dos índices RGB e multiespectral para as imagens terrestres e aéreas em cada condição de crescimento podem ser vistas na tabela 4.5. A altitude do sensor do dossel teve um efeito negativo na resolução das imagens ao usar câmeras com a mesma resolução (16 megapixels tanto no ar quanto no solo). No entanto, apesar dessa perda de resolução, os índices aéreos tiveram um desempenho muito semelhante ou até melhor do que as medições do solo.

**Tabela 4.5.** Efeito das práticas de lavoura e localização dos sensores (terrestre versus aéreo) nos índices RGB

		<b>Intensidade</b>	<b>Matiz</b>	<b>Saturação</b>	<b>Clareza</b>
Terrestre	CL	0.37±0.00	48.04±0.97	0.19±0.00	44.01±0.28
	CD	0.36±0.00	39.96±0.91	0.25±0.00	42.81±0.19
Aéreo	CL	0.49±0.00	38.25±0.75	0.19±0.00	54.96±0.35
	CD	0.49±0.00	31.38±0.49	0.19±0.00	55.25±0.48

Os resultados sugerem que, mesmo nos estágios iniciais de crescimento da safra, os diferentes índices RGB e multiespectrais têm o potencial de avaliar efetivamente as diferenças de rendimento sob condições de CL, mesmo que seu desempenho seja menor do que nas condições de CD.

#### 4.16 Estudo SCO2

**Relevância:** Extrema

O estudo SCO2, intitulado "Unmanned aerial system assisted framework for the selection of high yielding cotton genotypes"[20], de 2018, tem como objetivo desenvolver uma estrutura sistemática para selecionar cultivares de alto rendimento usando dados adquiridos de drones para que a estrutura desenvolvida possa ser usada para capacitar melhoristas para aprimorar seu processo de seleção de cultivares.

Um ensaio de campo em terra firme foi estabelecido no Texas, EUA. SCO2 foi realizado com o VANT DJI Phantom 2 Vision Plus e sua câmera padrão, com resolução de 14 megapixels e campo de visão de 110° horizontais e 85° verticais. O drone foi programado para voar a 30 m de altura, com 85% de sobreposição de imagem. A missão foi traçada utilizando a aplicação Pix4D.

A imagem ortomosaica foi classificada em classes de copa e não-copa aplicando o algoritmo de Canopeo[21]. Ao reduzir a população original de 144 parcelas para as melhores 5, 4 de 5 parcelas estavam presentes nas listas de drone e de colheita de campo, o que representa uma precisão de 80% para o procedimento de seleção baseado em drone.

No lado UAS, o rendimento médio de pluma das últimas 32 parcelas, a partir do procedimento de seleção por etapas, foram calculados, o que resultou em uma lista de 24 genótipos individuais. Destes, 15 genótipos foram selecionados

para comparação com a lista de produção de pluma colhida. Assim, 11 dos 15 genótipos estavam presentes em ambas as listas, o que representa 73% de precisão.

O processo de seleção aumentou o rendimento mínimo e médio de fibra da população restante em 7.4 e 10%, respectivamente. Entradas e genótipos selecionados dos drones corresponderam a 80 e 73%, respectivamente, as mesmas listas classificadas pelas medições reais de colheita de campo. É importante notar, no entanto, que essa tecnologia e as metodologias a ela associadas não buscam, de maneira alguma, substituir melhoristas vegetais. Os melhoristas devem considerar a tecnologia como uma ferramenta para auxiliar e acelerar seu trabalho.

#### 4.17 Estudo SCD9

**Relevância:** Baixa

O estudo SCD9, intitulado "Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle"[22], de 2017, buscou desenvolver um fluxo de trabalho de fenotipagem de alta produtividade a fim de estimar o índice de vegetação de diferença normalizada (NDVI) no nível da parcela através de um veículo aéreo não tripulado (VANT) e uma câmera espectral múltipla; comparar o NDVI medido a partir de VANTs a um sensor portátil de mão; melhorar a precisão do NDVI do VANT através da fusão de dados de câmera de mão de alta resolução; e caracterizar NDVI para contrastes de cultivares, manejos e ambientes.

SCD9 ocorreu em Queensland, Austrália. A princípio, foi utilizado um drone movido a gasolina da marca **PhenoCopter**; no entanto, ele foi substituído por um modelo elétrico comercial (**Iris** + quadricóptero da empresa **3DR Robotic Systems**). Além disso, usou-se a câmera multi-espectral **Micasense RedEdge** com uma resolução de  $1280 \times 800$  com 5 bandas (azul, verde, vermelho, infravermelho próximo e red edge). Os voos foram programados para ocorrer a 30 ou 50 m de altura e velocidade de 3 m/s, com sobreposição de 70% frontal e 80% lateral. O tamanho de pixel foi aproximadamente 1.8 cm para voos de 30 m e 3 cm para voos de 50 m de altitude.

O experimento mostrou que retirar o fundo do solo das imagens pode fornecer resultados mais precisos para alguns índices. O NDVI ajustado ao solo (NDVI-A) no momento de florescimento e o rendimento final apresentaram uma correlação relativamente maior ( $R^2 = 0.87$ ) do que o NDVI bruto (NDVI-R,  $R^2 = 0.82$ ) após minimizar a influência do solo. Também é possível usar uma câmera de alta resolução no drone ao invés de tirar fotos no chão.

As medições dadas por VANT e câmera aérea foram fortemente relacionadas aos valores medidos por sensores portáteis, com a vantagem de serem coletadas mais rapidamente.

#### 4.18 Estudo SCD10

**Relevância:** Baixa

O estudo SCD10, intitulado "Exploring Robots and UAVs as Phenotyping Tools in Plant Breeding"[23], de 2017, explora como imagens multi-espectrais podem ser usadas como uma tecnologia de fenotipagem na pesquisa de melhoramento vegetal. Isso inclui o desenvolvimento e teste de imagens em comprimentos de onda visíveis e próximas ao infravermelho de plantações em teste de campo, usando câmeras acopladas a robôs autônomos de campo e veículos aéreos não tripulados (VANTs).

O estudo foi realizado no sudeste da Noruega. Foi utilizado o drone **Phantom 3** da empresa **DJI** e uma câmera multi-espectral **Parrot Sequoia** com três canais espectrais de banda larga (verde, vermelho e infravermelho próximo), um canal de banda estreita, e um sensor RGB. A altitude de voo se deu a 15 m acima do solo.

A integração de sensores multiespectrais em VANT e robô fornece uma solução de levantamento medida aprimorada e flexível com dados precisos capturados no local. As imagens NDVI calibradas obtidas por detecção aérea confirmam as medições realizadas no nível do solo e podem ser usadas para calcular as datas de projeção e estimativa de produção. No entanto, as imagens do robô exibem detalhes próximos das plantas que podem ser exploradas por meio de análise avançada de imagens.

#### 4.19 Estudo SCD11

**Relevância:** Baixa

O estudo SCD11, intitulado "Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery"[24], de 2017, tem como objetivo principal adaptar as observações por VANT do método desenvolvido por Liu para estimativa de densidade vegetal e avaliação da precisão de estimativa associada.

O experimento foi realizado nas regiões de Gréoux e Avignon, com clima mediterrâneo; e Clermont, com clima continental. O drone usado foi um hexacóptero da empresa **Atechsys** com uma câmera de RGB **SonyILCE α5100L** de alta resolução. A câmera estava apontada para a plantação a um ângulo de  $45^\circ$  zenite e acoplada a um gimbal de dois eixos. Os voos foram realizados a uma velocidade de 1 m/s e uma altitude que variou entre 3 e 7 m, dependendo da região. A resolução da câmera era de  $6024 \times 4024$  pixels; ela usou um sensor CMOS de  $23.5 \times 15.6$  mm com tamanho de pixel de  $3.88 \mu\text{m}$  e estava equipada com uma lente focal de 60 mm.

Sob as condições variáveis avaliadas, os desempenhos de recuperação da densidade da planta fornecem RMSE entre 21.66 e 52.35 plantas/ $m^2$  para densidades que variam de 79 a 388 plantas/ $m^2$ , correspondendo a valores relativos de RMSE que variam de 9.24% a 17.12%, ou seja, perto das incertezas de 10%, muitas

**Tabela 4.6.** Resumo das principais características de voo para três locais experimentais

Localidade	Altitude (m)	Resolução do solo (mm)	Sobreposição (paralelo/transversal) (%)	Tamanho da subamostra
Gréoux	3	0.2	38/80	1.5 m×3 linhas
Avignon	5	0.33	62/80	0.5 m×2 linhas
Avignon	7	0.45	73/80	0.5 m×2 linhas
Clermont	7	0.45	73/80	2.5 m×3 linhas

vezes consideradas como a precisão alvo a ser alcançada. Os melhores desempenhos requerem uma resolução espacial melhor que 0.40 mm para facilitar a classificação dos pixels verdes e a recuperação do número de plantas por objetos de imagem feitos de várias plantas sobrepostas.

Os objetos de imagem foram identificados usando a função `bwlabel` do MATLAB. Os voos de baixa altitude necessários induzem potenciais problemas para as técnicas fotogramétricas usadas para recuperar as posições precisas das câmeras quando a imagem é adquirida. Alternativamente, o uso de um sistema de precisão centimétrica combinado com a informação da IMU (unidade de medida inercial) permite orientar diretamente a imagem na superfície do solo com precisão suficiente: devido à baixa altitude, as incertezas na orientação da câmera vinda da IMU irão se traduzir em erros de posicionamento limitados.

A geometria das observações afeta significativamente as estimativas de densidade de plantas e, devido à maneira relativamente fácil e automática de coletar e processar as imagens, a estimativa da densidade de plantas poderia ser aplicada sobre grandes amostras.

#### 4.20 Estudo EIC6

**Relevância:** Alta

O estudo EIC6, intitulado "Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine"[25], de 2017, procura estimar os teores de clorofila *a* (*Chl a*), clorofila *b* (*Chl b*) e clorofila *a + b* (*Chl a + b*), concentração de nitrogênio, biomassa fresca e seca acima do solo, e índice de área foliar (IAF) combinando dados RGB, multiespectrais, e térmicos adquiridos por drones usando ambos os métodos estatísticos empíricos selecionados de Regressão Parcial dos Mínimos Quadrados (PLSR) e Machine Learning (ML).

Uma campanha de campo, destinada a coletar imagens RGB, multiespectrais e térmicas baseadas em drone, bem como métricas fenotípicas do solo, foi conduzida em Columbia, Missouri, EUA. Experimentos utilizaram um hexacóptero DJI S900 com uma câmera RGB Sony Alpha ILCE-7R e um gimbal Ronin de três eixos. Imagens térmicas e multi-espectrais foram obtidas a partir de sensores

ICI 8640 P-series e Parrot Sequoia, respectivamente. Voos foram conduzidos a uma altitude de 3 m para uma sobreposição desejada de 90% frontal e 80% lateral a fim de garantir redundância de imagem.

Na predição das características da soja a partir da fusão de dados multi-sensor, a ELR demonstra um desempenho relativamente superior em comparação com a PLSR e a RVS. A fusão de dados multi-espectrais e térmicos forneceu a melhor estimativa para a concentração de nitrogênio e clorofila *a*. Em contraste, os índices baseados em informações de cores RGB e fusão de dados multi-espectrais exibiram o maior RMSE (22.6%). A fusão dos três sensores superou a combinação de quaisquer dois sensores, bem como sensores únicos para previsão de *Chl a + b* (menor RMSE - 11,6%).

Entre as características biofísicas da planta, a fusão de dados RGB e térmicos, que combina cor, estrutura da copa e informações de temperatura, resultou em melhores previsões para o IAF, enquanto a fusão de dados térmicos e multi-espectrais foi melhor para estimativa de biomassa.

Os resultados deste estudo demonstram que a fusão de baixo custo de dados de múltiplos sensores dentro de uma estrutura de aprendizado de máquina podem fornecer estimativas precisas relativas de fenótipos de plantas. Vale ressaltar que a fusão de dados pode melhorar a precisão das estimativas de fenótipo; no entanto, para identificar os dados do sensor combinados de forma mais precisa e eficiente para a fusão, estudos mais abrangentes são necessários, incluindo estudos sobre diferentes espécies de culturas. Além disso, a fusão de dados nem sempre melhora drasticamente a exatidão da previsão. Assim, uma troca entre a melhoria da precisão e o custo do uso de múltiplos sensores deve ser considerada para uma aplicação específica.

#### 4.21 Estudo EIC7

**Relevância:** Alta

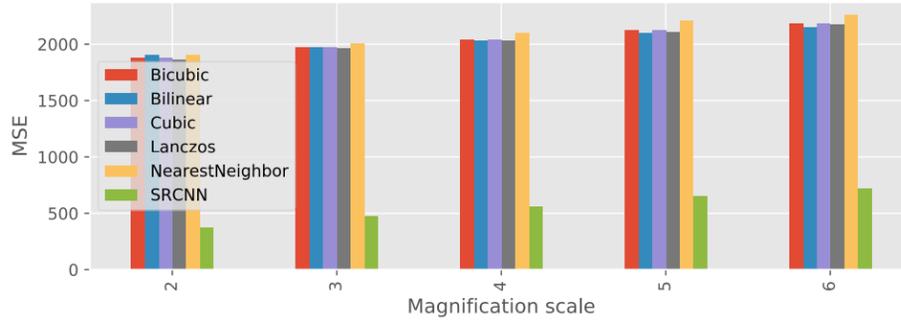
O estudo EIC7, intitulado "Super-Resolution of Plant Disease Images for the Acceleration of Image-based Phenotyping and Vigor Diagnosis in Agriculture"[26], de 2017, teve como objetivo avaliar o desempenho de métodos de super-resolução em aplicações agrícolas, especialmente classificação de doenças de plantas.

Os resultados de avaliação quantitativa, observados nas figuras 4.1, 4.2 e 4.3, indicam que o SRCNN apresentou o melhor dentre todos os métodos em qualquer escala de ampliação em termos de MSE, PSNR e SSIM. No SRCNN, o MSE foi menor em pelo menos 1428, e o PSNR e o SSIM foram maiores em pelo menos 0.51 e 0.02 do que outros métodos.

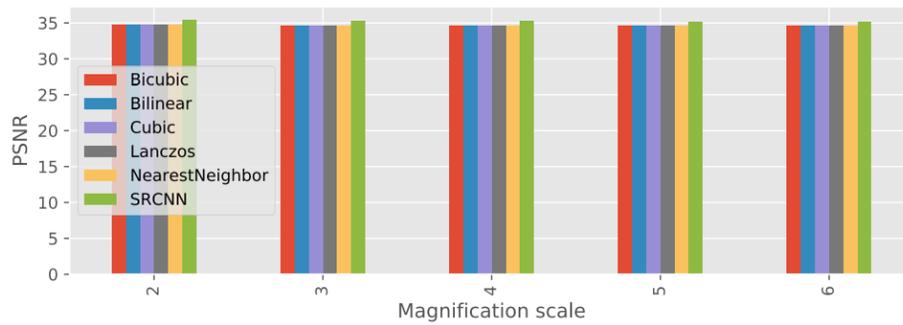
A precisão alcançada em relação à classificação de doenças foi mais alta quando imagens originais foram usadas para testes. A precisão obtida usando imagens de super-resolução foi melhor que a obtida usando imagens de baixa resolução geradas por qualquer tipo de método em todas as escalas de ampliação (figura 4.4).

O resultado das avaliações qualitativas mostrou que as imagens produzidas pela SRCNN foram mais claras e menos desfocadas do que as imagens de baixa

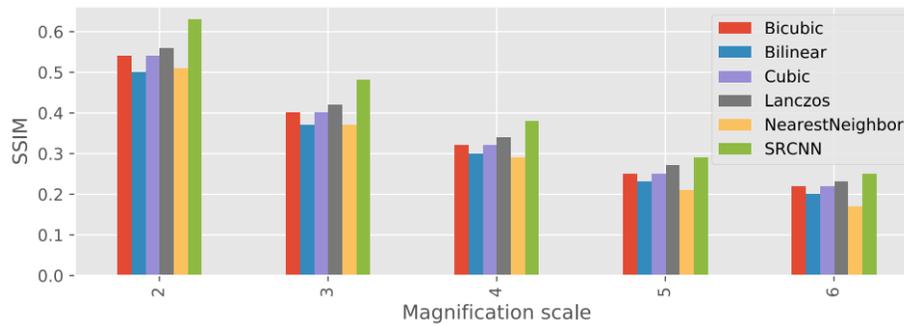
**Figura 4.1.** Comparação dos resultados quantitativos médios produzidos pelo MSE para diferentes escalas de ampliação



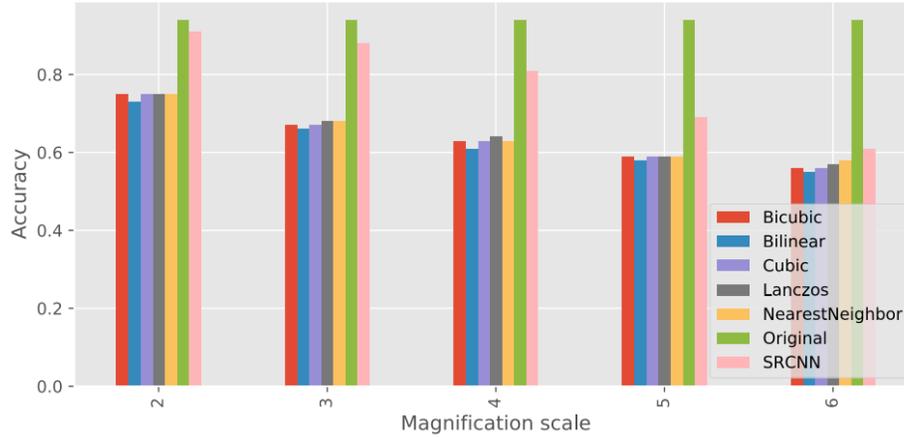
**Figura 4.2.** Comparação dos resultados quantitativos médios produzidos pelo PSNR para diferentes escalas de ampliação



**Figura 4.3.** Comparação dos resultados quantitativos médios produzidos pelo SSIM para diferentes escalas de ampliação



**Figura 4.4.** Precisão da classificação de doenças usando imagens de alta resolução, baixa resolução e super-resolução em diferentes escalas de ampliação



resolução geradas por 5 métodos convencionais diferentes. Isso significa que o SRCNN foi capaz de restaurar a informação que estava nas imagens originais e foi perdida nas imagens de baixa resolução. O resultado da avaliação quantitativa demonstrou o resultado de avaliações qualitativas: MSE de imagens originais foi menor e PSNR e SSIM foram maiores do que para imagens de baixa resolução em todas as escalas de ampliação.

Além disso, SRCNN superou os outros métodos convencionais na classificação da doença por uma grande margem em escalas de ampliação de 2 a 5, e uma pequena margem ( $\geq 0.03$ ) em escala 6. A falha de super-resolução ocorreu por cerca de 2% das imagens de teste. Algumas das falhas foram devidas a objetos inesperados, principalmente o dedo do fotógrafo.

## 4.22 Estudo IEEE2

**Relevância:** Baixa

O estudo IEEE2, intitulado "Plant Leaf Segmentation for Estimating Phenotypic Traits"[27], de 2017, estima características fenotípicas ao nível da planta a partir de imagens de VANTs. É descrito, ainda, um método para segmentar folhas individuais.

IEEE2 foi realizado em West Lafayette, Indiana, EUA. O voo do drone se deu a 40 m de altitude e velocidade de 8 m/s.

Puderam ser obtidas características fenotípicas como a área e o comprimento de cada folha e a contagem foliar de cada planta.

O método foi avaliado usando 10 plantas selecionadas, com 82 folhas. Destas 82 folhas, um total de 57 folhas verdadeiras positivas foram corretamente detectadas, um total de 18 folhas falso-positivas foram detectadas, o que significa que

18 segmentos ruidosos da imagem foram detectados incorretamente como folhas. Dessas 82 folhas, o método produziu um total de 25 amostras falso-negativas, o que significa que 25 folhas não puderam ser detectadas, levando a uma precisão de 69.5% e recall de 76.0%. O comprimento e a área da folha, por sua vez, foram estimados em 98 pixels e 1000 pixels quadrados, respectivamente.

#### 4.23 Estudo IEEEE3

**Relevância:** Baixa

O objetivo do estudo IEEEE3, intitulado "Improving Orthorectification of UAV-Based Push-Broom Scanner Imagery Using Derived Orthophotos From Frame Cameras"[28], de 2017, é analisar resultados experimentais de conjuntos de dado reais adquiridos por VANTs para demonstrar a viabilidade e o desempenho do procedimento proposto para melhorar as características geométricas das ortofotos hiperespectrais.

IEEEE3, assim como IEEEE2, foi realizado em West Lafayette, Indiana, EUA. O estudo utilizou um quadricóptero Phantom 2 da empresa DJI e uma câmera GoPro Hero 3+ (Black Edition) com largura focal nominal de 3 mm. Os voos ocorreram a uma velocidade de 8 m/s e altura de 15 m.

O procedimento de registro proposto foi bem-sucedido na redução da qualidade do ajuste entre características de amarração e verificação, de aproximadamente  $\pm 2.5$  m para quase  $\pm 0.25$  m. Usar um número maior de pontos de amarração e recursos lineares não melhora significativamente a qualidade do ajuste, assim como a utilização de um polinômio de interpolação de segunda ordem entre os pontos de referência. Usar um maior número de pontos de referência, no entanto, o faz.

O procedimento proposto pode funcionar na ausência de recursos de ponto de amarração e é mais prático usar um número maior de pontos de referência e reduzir a ordem do polinômio de interpolação entre os pontos de referência, o que evitará problemas de excesso de parametrização.

Apesar de VANTs equipados com RGB e sistemas hiper-espectrais de imagem serem plataformas promissoras para fenotipagem de alta produtividade a baixo custo, as restrições de carga útil e resistência de tais plataformas impõem a utilização de unidades de georreferenciamento direto do consumidor com a modesta capacidade de determinar a posição e a orientação dos sensores envolvidos.

#### 4.24 Estudo IEEEE4

**Relevância:** Baixa

O estudo IEEEE4, intitulado "Prediction of Sorghum Biomass Based on Image Based Features Derived from Time Series of UAV Images"[29], de 2017, investiga dois algoritmos de aprendizagem estatísticos não lineares, MLP e SVR, para predição de biomassa seca.

O estudo ocorreu em West Lafayette, Indiana, EUA. O drone utilizado foi um multi-rotor S1000+ da empresa DJI, com uma câmera Sony Alpha 7R de lente 35 mm. Os voos aconteceram a 55 m de altura e velocidade de 10 m/s. A câmera em questão possuía resolução de 35 megapixels, resultando em uma distância da amostra de solo de 0.75 cm. Os dados hiper-espectrais foram obtidos a partir de um sistema de varredura eletrônica Headwall Nano-Hyperspec.

Os modelos SVR e MLP foram treinados e dez experimentos foram conduzidos com diferentes recursos de entrada. Os resultados médios da validação cruzada estão listados na tabela 4.7 e mostram que combinar altura e dados espectrais melhorou a capacidade de previsão. Além disso, o  $R^2$  aumentou a medida que mais recursos de várias datas foram incorporados, especialmente para o modelo SVR.

**Tabela 4.7.** Precisões de previsão de biomassa para diferentes experimentos

Experimento	SVR		MLP	
	RMSE ( $g/m^2$ )	$R^2$	RMSE ( $g/m^2$ )	$R^2$
1	205.28	0.48	213.83	0.43
2	179.33	0.58	180.36	0.60
3	265.17	0.13	274.88	0.04
4	220.44	0.46	239.00	0.37
5	187.42	0.61	188.40	0.61
6	178.89	0.65	199.19	0.55
7	174.11	0.66	199.19	0.55
8	161.31	0.71	188.38	0.61
9	15.41	0.73	184.15	0.62
10	48.02	0.76	196.30	0.57

O modelo SVR, em geral, funciona melhor que o modelo MLP. Isso provavelmente ocorre porque os dados de referência do solo para biomassa foram extremamente limitados, e o grande número de parâmetros de ponderação associados às características de alta dimensão não puderam ser aprendidos apropriadamente.

Os resultados mostram que combinar recursos espectrais e de altura em várias datas pode resultar em um melhor desempenho de previsão do que usar um único tipo de recurso ou recursos de uma única data. No entanto, devido à quantidade limitada de dados de referência do solo, os desempenhos dos modelos foram sub-ótimos, especialmente para MLP, uma vez que normalmente é necessária uma grande quantidade de amostras de treinamento para aprender os pesos ideais.

#### 4.25 Estudo SCO3

**Relevância:** Baixa

O estudo SCO3, intitulado "The DOM Generation and Precise Radiometric Calibration of a UAV-Mounted Miniature Snapshot Hyperspectral Imager"[30], de 2017, buscou gerar um mapa de ortofoto digital a partir de cubos hiperespectrais capturados por um espectrômetro leve de imagem montado em uma plataforma de VANT equipado com um sistema de posição e orientação e uma unidade de medição inercial que executa uma calibração radiométrica precisa.

SCO3 foi conduzido em Xiaotangshan, Beijing, China, e contou com um VANT multi-rotor **Spreading Wings S1000+** da DJI, assim como uma câmera digital **Sony DSC-QX100** associada a um espectrômetro **UHD 185**. Os voos foram realizados a uma altitude de 50 m, com velocidade de 5 m/s, e as distâncias de amostra de solo foram de 0.017 m e 0.34 m para imagens PAN e hiperespectrais. Sobreposições de imagens se deram em 70% frontal e 60 % lateral.

Os resultados indicaram que o dispositivo de carga acoplada do sensor hiperespectral exibiu um notável efeito de vinheta e tiras. Medidas foram tomadas para corrigir o desvio espectral e a variação da resposta radiométrica. A variação da resposta radiométrica foi significativamente eliminada após a correção. O sensor hiperespectral **UHD 185** tem vantagens em relação à eficiência de imagem. Resultados de calibração robusta foram alcançados após a calibração espectral e radiométrica, não mostrando predisposições significantes para imagens calibradas; discrepâncias ficaram abaixo de 5% para todas as bandas.

Foi avaliada a exatidão geométrica do método introduzido para calcular as informações de POS de imagens hiperespectrais, comparando os mapas de ortofoto digital (DOM) e modelos de elevação digital (DEM) gerados pela fotogrametria convencional de VANT com os de uma câmera digital comercial; a diferença horizontal relativa foi menor que 0.05 m. O portfólio de pré-processamento proposto mostrou-se robusto, confiável, eficaz em termos de tempo e eficiente em recursos. As vantagens de usar os imageadores hiperespectrais instantâneos incluem um aumento significativo na eficiência da coleta de luz, falta de artefatos de varredura e maior robustez ou compactação devido à falta de componentes móveis.

#### 4.26 Estudo SCO4

**Relevância:** Média

O estudo SCO4, intitulado "UAV Localization in Row Crops"[31], de 2017, desenvolve um procedimento para estimar a altitude e a posição lateral do VANT para uma linha de milho usando apenas o scanner a laser e unidade de Medida Inercial (IMU).

Nesse trabalho, é usado um hexacóptero **Firefly** da empresa **Ascending Technologies**. Micro-VANTs são as plataformas ideais para esse estudo, devido à sua alta mobilidade e capacidade de voar acima das culturas, mostrando-se útil

onde um robô de solo apresentaria dificuldades. O sensor primário utilizado é um scanner a laser Hokuyo UBG-04LX-F01 2D, escolhido graças ao seu desempenho externo, invariância às condições de iluminação, alta resolução de dados espaciais e rápida taxa de detecção. O drone é equipado com um IMU de 9-DOF, um altímetro barométrico, uma câmera mvBlueFOX MLC200wC de  $752 \times 480$  pixels, e um GPS.

Fechando o circuito de detecção e controle permite que o drone controle sua postura em 2-DOFs em um campo de teste de fenotipagem ao ar livre. Esta experiência demonstra a capacidade do sistema de voar e localizar-se de forma estável para uma linha de campo de destino. A tabela 4.8 mostra as métricas de erro para todos os voos. Os erros com a maior magnitude demonstram que o drone e os observadores sempre concordam com a localização do drone em uma linha. A média combinada (-0.053), desvio padrão (0.294), e mediana (-0.057) mostram que os erros tendem em uma direção. Apesar da grande variação nas estimativas, o drone voa de forma estável ao longo da linha alvo.

Os erros são, por vezes, resultado do drone ou da incorreta identificação do observador sobre qual linha ele está sobrevoando. No entanto, os erros não parecem ter uma dependência do tempo ou da distância percorrida pelo VANT e mostram que o drone não perde o controle da linha de destino em longo prazo.

**Tabela 4.8.** Estatísticas de erro para voos 2-DOF

Voo	Média (m)	Desvio padrão	Mediana (m)	Max (m)
1	0.164	0.226	0.192	0.482
2	-0.031	0.296	-0.093	0.932
3	-0.322	0.387	-0.070	1.012
4	-0.172	0.251	-0.139	0.904
5	-0.113	0.108	-0.144	0.256
6	0.141	0.260	0.078	0.800
7	-0.026	0.293	-0.095	0.808
8	-0.142	0.129	-0.165	0.313
9	-0.315	0.322	-0.195	1.038
10	0.045	0.180	0.027	0.553
11	-0.056	0.227	-0.109	0.591
Combinados	-0.053	0.294	-0.057	1.038

Para 3-DOF, em vez de seguir a linha de destino, o drone segue a linha adjacente durante a maior parte do voo. Adicionando um offset de  $\pm r_w$ , o experimento mostra que o drone, ao detectar corretamente a rota para uma fila adjacente mesmo que apenas uma vez, melhorará drasticamente seu desempenho de rastreamento. Os resultados são vistos na tabela 4.9 e, embora o sistema ainda tenha uma grande variação e, ocasionalmente, desvalorize sua posição, o erro é quase zero. Isso demonstra que os erros não se acumulam e que o drone pode controlar eficientemente as linhas.

**Tabela 4.9.** Estatísticas de erro para voos 3-DOF

Voo	Média (m)	Desvio padrão	Mediana (m)	Max (m)
1	0.134	0.921	0.083	1.625
2	0.214	0.713	0.210	1.448
3	0.069	0.354	0.098	1.076
4	-0.204	0.354	-0.160	1.117
5	-0.032	0.678	0.145	1.655
6	0.071	0.278	0.067	0.641
7	-0.085	0.520	-0.075	1.121
Combinados	0.028	0.611	0.043	1.655

Em todos os casos estudados, a diferença na posição relatada pelo GPS está próxima da distância entre as fileiras de milho em um estudo de fenotipagem. Este nível de precisão é insuficiente para caracterizar as respostas das plantas nos ensaios de fenotipagem, motivando a necessidade de soluções de localização adicionais.

O sistema baseado em laser apresentado é vulnerável a trocar a linha que está rastreando; então, a fusão de uma estimativa de sensor adicional na estimativa de posição que reduz esse ruído pode melhorar muito o sistema. Um sistema mais confiável pode fornecer estimativas de localização robustas, permitindo navegação livre de GPS, tolerância a falhas quanto às falhas do GPS, e um meio de localizar precisamente o veículo sem a necessidade de sistemas de GPS RTK.

#### 4.27 Estudo SCO5

**Relevância:** Baixa

O estudo SCO5, intitulado "Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution"[32], de 2017, avalia o potencial de analisar imagens RGB simples através de um campo de cevada de primavera experimental com alta frequência temporal e resolução espacial, com o intuito de correlacionar o resultado com os estágios de desenvolvimento da safra.

SCO5 foi realizado em Rheinbach, Alemanha. O drone usado durante o estudo foi um *Falcon-8* da empresa *Asctec GmbH*, equipado com uma câmera RGB *Sony NEX 5n* com resolução de  $4912 \times 3264$  pixels e lente focal de largura 16 mm. O voo se deu a uma altitude de 100 m acima do solo, resultando em uma resolução de  $20 \times 20$  mm por pixel.

A cadeia de processamento de dados simples é rápida e mostrou-se robusta contra diferentes condições de iluminação. Porém, o uso de imagens RAW e uma câmera totalmente calibrada radiometricamente poderia aumentar ainda mais a precisão dos dados.

A alta resolução temporal do conjunto de dados é um pré-requisito para observar as rápidas mudanças na refletância do dossel, que não podem ser de-

tectadas por apenas alguns sobrevoos de drones. É notável que o padrão para cultivares de cevada e ambos os anos são conservados, portanto, é provável que a abordagem também possa ser aplicada a outras culturas para acompanhar seu desenvolvimento sazonal.

Enquanto fenotipagem acontece em uma escala espacial relativamente pequena em campos experimentais limitados, pecuária de precisão depende de informações sobre regiões maiores. Então, imagens poderiam ser fornecidas para fenotipagem por pequenas plataformas voadoras, que podem ser implantadas diariamente, como os drones usados neste estudo. Devido ao seu modo ineficiente de voar, drones apresentam performance pior que aviões não tripulados ou até mesmo tripulados, que podem cobrir grandes áreas em um tempo relativamente curto.

#### 4.28 Estudo SCO6

**Relevância:** Alta

O estudo SCO6, intitulado "Digital Counts of Maize Plants by Unmanned Aerial Vehicles (UAVs)"[33], de 2017, busca avançar o uso de VANTs e análise de imagens como uma possível técnica de fenotipagem de alta produtividade.

O experimento de campo foi conduzido em Dürnast, no sul da Bavaria, com temperatura média de 8.1 °C e 791 mm de precipitação. SCO6 utilizou o VANT MK Basicset Okto2 da empresa KS Model Company Ltd. e uma câmera digital Canon G12, com 10 megapixels, largura focal de 28 mm, e qualidade de imagem de 180 pixels/polegada. As imagens obtidas apresentaram sobreposição de, em média, um terço. Os voos ocorreram a uma altura de 50 m.

A correlação entre a porcentagem de pixels verdes e as plantas registradas visualmente nas parcelas indicou pouca relação ( $R^2 = 0.023$ ), o que sugere que não existe relação entre cobertura do solo e número de plantas. A detecção digital de plantas, portanto, não foi possível. Para registrar o número digital de plantas em cada imagem, a imagem original foi processada com o procedimento de realce de contraste *decorrstretch*[34].

O script de processamento de imagens pôde ser usado nos primeiros estágios de desenvolvimento de folhas em ambos os sistemas de plantio, permitindo a segmentação bem-sucedida de plantas jovens. Uma segmentação boa e clara, no entanto, depende do tipo de objeto e/ou da região. Imagens desfocadas não representaram erros significativos na diferenciação de plantas contadas visualmente e digitalmente.

A propagação das diferenças entre plantas contadas digital e visualmente foi inferior a 10% para todas as cultivares, com apenas três outliers excedendo essa faixa. Essas diferenças podem ser devidas a vários fatores - imagens tardias demais do crescimento das plantas podem não permitir a separação das folhas mais jovens das mais velhas; e as plantas que estão muito juntas, com efeitos de sobreposição aumentados, podem resultar na contagem de menos plantas.

O uso de VANTs fornece dados de economia de custos e tempo para posterior processamento e permite coletas de dados flexíveis e independentes do tempo.

Os resultados deste estudo demonstram a capacidade de processamento de imagens em campos agrícolas para detectar pós-emergência de plantas. A detecção da cobertura do solo não se correlacionou com o número de plantas no nível da parcela. Tornou-se possível a contagem de plantas apenas introduzindo o comando *decrrstretch* do MATLAB. Efeitos de embaçamento e detecção de ervas daninhas em imagens podem levar a erros de contagem, que podem ser evitados selecionando manualmente os limites e agrupando os pixels.

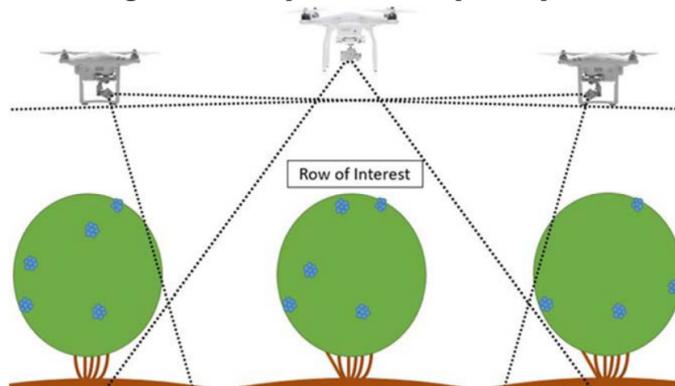
#### 4.29 Estudo SCO7

**Relevância:** Alta

O estudo SCO7, intitulado "High Throughput Phenotyping of Blueberry Bush Morphological Traits Using Unmanned Aerial Systems"[35], de 2017, possui como objetivo geral determinar a viabilidade e precisão do uso de um sistema VANT para adquirir imagens a fim de extrair características morfológicas de arbusto de mirtilo que são relevantes para colheitas realizadas por máquinas. Entre os objetivos específicos estão: determinar parâmetros ótimos para o drone e câmeras a bordo para coleta de dados de imagens aéreas; usar imagens para gerar nuvens de pontos e extrair características morfológicas do modelo 3D; e quantificar as métricas de forma para uma capacidade de colheita da máquina desejável e comparar variedades de arbustos.

SCO7 foi conduzido em Athens, Georgia, EUA; e utilizou um quadricóptero Phantom 3 Advanced da DJI, com sua câmera padrão de largura focal de 20 mm. Para a obtenção das imagens, a câmera foi direcionada à plantação perpendicularmente, assim como a um ângulo de 45 graus para a esquerda e direita, como pode ser observado na figura 4.5. Os voos ocorreram de 3 a 8 m de altitude e velocidade de 0.4 m/s. Os ângulos de visão horizontal e vertical foram determinados em aproximadamente 82.5 e 66.5 graus, respectivamente.

**Figura 4.5.** Campo de visão do quadricóptero



Os resultados revelaram que as características morfológicas obtidas das imagens aéreas foram muito próximas das características medidas manualmente, como extensão do arbusto (altura e largura), área do dossel e volume, podendo substituir medições manuais em campo a fim obter uma economia significativa de mão-de-obra.

Quando comparadas ao sistema baseado em LiDAR (terrestre ou aéreo), imagens de baixa altitude por drone não apenas oferecem um alto rendimento e baixo custo de coleta de dados morfológicos, como também fornecem informações de cor que ajudam a diferenciar as touças da grama ou outra vegetação.

Este estudo confirma a viabilidade da utilização de imagens de estruturas aéreas não tripuladas e de algoritmos de movimento para gerar modelos 3D de arbustos dos quais traços morfológicos podem ser extraídos. As nuvens de pontos geradas a partir das imagens tinham dimensões comparáveis àquelas medidas manualmente em campo. Imagens georreferenciadas tiradas de uma altitude baixa e de vários ângulos forneceram dados adequados para caracterizar arbustos de forma confiável. Resultados semelhantes poderiam ter sido atingidos com menos fotos tiradas a uma altura mais elevada, o que forneceria maior cobertura em menos tempo.

#### 4.30 Estudo SCD12

**Relevância:** Baixa

No estudo SCD12, intitulado "Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle"[36], de 2016, um drone com uma câmera digital é utilizado como uma plataforma de fenotipagem para a avaliação da resistência de batatas à requeima.

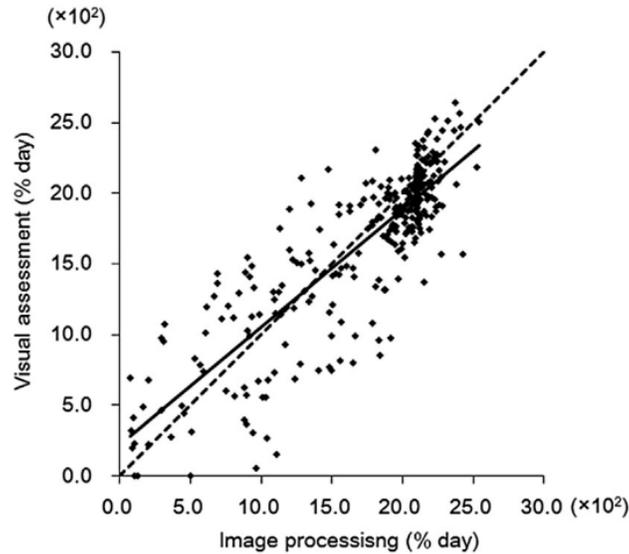
SCD12 foi realizado em Hokkaido, Japão. As imagens foram obtidas a partir de um drone HiSystems GmbH Mikrokoopter e uma câmera Sony NEX-5N. A câmera possuía ângulos de visão de 52.4° verticais e 73.1° horizontais, e a imagem apresentava 3264×4912 em dimensão de pixel, e resolução espacial de 2.4 cm  $pixel^{-1}$ . Os voos ocorreram a 80 m do solo.

O coeficiente de determinação entre as áreas abaixo das curvas de progresso da doença (AACPDs) pelo processamento de imagem e avaliação visual foi de 0.73, como pode ser observado na figura 4.6. A linha contínua mostra a linha de regressão,  $y = 0.83x + 217.11$ .

Os resultados da gravidade da doença e estimativas de AACPD foram ligeiramente piores do que os do ano anterior; no entanto, os criadores concluíram que a precisão ainda era aceitável para a gravidade da doença e medições de AACPD. Portanto, o método desenvolvido com base no processamento de imagens foi validado como uma ferramenta efetiva de fenotipagem de resistência à requeima.

Os resultados sugerem que o método aéreo baseado em imagens RGB poderia ser um sistema de fenotipagem de larga escala para avaliar a resistência à doença. Ficou claro que a avaliação da gravidade e da resistência à doença por meio de imagens são muito mais eficientes do que a avaliação visual convencional.

**Figura 4.6.** Correlação entre as AACPDs dos métodos de processamento de imagem e avaliação visual no conjunto de dados de validação do ano seguinte



#### 4.31 Estudo SCD13

##### Relevância: Média

O estudo SCD13, intitulado "Evaluation of ground, proximal and aerial remote sensing technologies for crop stress monitoring"[37], de 2016, buscou determinar a viabilidade do uso de imagens multiespectrais proximais terrestres e imagens multiespectrais baseadas em VANT para o monitoramento rápido do estresse de culturas em lavouras em fileiras irrigadas no cultivo de feijão carioca; e compreender o efeito da resolução sobre a quantificação do estresse das culturas nas fases iniciais do crescimento.

A região de SCD13 é próxima à cidade de Prosser, EUA, onde foram plantadas oito cultivares de feijão carioca. Foi utilizado o VANT ARF OktoXL 6S12 da empresa HiSystems GmbH em conjunto com uma câmera multi-espectral Nite Canon ELPH110 LDP LLC com bandas infravermelho próximo (NIR), verde e azul. Os sensores de imagem possuíam 4 mm de largura focal e resolução de  $4608 \times 3456$  pixels. Os voos ocorreram a 100 m de altitude, resultando em distâncias de amostra de solo de  $35.2 \text{ mm} \cdot \text{pixel}^{-1}$ .

No geral, a correlação entre o rendimento da cultura e o GNDVI foi forte em todo o gráfico de sensoriamento remoto aéreo ( $r = 0.71$ ), que foi semelhante às correlações entre rendimento e indicadores de cobertura de dossel (CD) de imagens de sensoriamento remoto e IAF de sensoriamento do solo, mas ligeiramente

superior aos dados de sensoriamento remoto proximal, como pode ser observado na tabela 4.10.

A possível razão para a correlação relativamente fraca dos dados de detecção proximal pode ser a variação da condição de luz, resultando em grande variação no GNDVI e na CD de diferentes subparcelas, uma vez que as imagens foram tiradas em diferentes momentos em um dado dia de coleta de dados.

**Tabela 4.10.** Coeficientes de correlação ( $r$ ) entre o rendimento da cultura e indicadores baseados em dados de detecção desenvolvidos

Cultivar	IAF	GNVI		Cobertura de dossel	
		Aéreo	Proximal	Aéreo	Proximal
C1	0.75	0.86	0.78	0.89	0.74
C2	0.86	0.86	0.80	0.82	0.88
C3	0.72	0.61	0.67	0.46	0.44
C4	0.58	0.81	0.70	0.78	0.68
C5	0.81	0.92	0.73	0.89	0.80
C6	0.58	0.50	0.61	0.44	0.56
C7	0.69	0.84	0.70	0.84	0.69
C8	0.69	0.80	0.48	0.80	0.56
<b>Geral</b>	0.70	0.71	0.65	0.72	0.64

Resultados indicam que ambos sensoriamentos remotos proximal e aéreo foram capazes de detectar a resposta das culturas a diferentes tratamentos de irrigação e preparo do solo, usando o GNDVI como índice indicador. No entanto, o índice de área foliar medido com sensoriamento proximal não conseguiu distinguir a diferença entre as culturas com dois tratamentos de cultivo no mesmo nível de irrigação; e a correlação com o rendimento foi mais forte nos dados de sensoriamento remoto aéreo. Em suma, o sensoriamento remoto aéreo com resolução espacial reduzida tem melhor potencial para monitorar o estresse da cultura em comparação com outros dois métodos estudados.

#### 4.32 Estudo SCD14

**Relevância:** Extrema

O estudo SCD14, intitulado "Machine Learning for High-Throughput Stress Phenotyping in Plants"[38], de 2016, fornece uma visão geral abrangente e uma taxonomia amigável de ferramentas de Machine Learning (ML) para permitir que a comunidade de plantas aplique de forma fácil e correta as ferramentas apropriadas de ML e as diretrizes de melhores práticas para vários traços de estresse bióticos e abióticos.

SCD14 proporciona uma visão geral do trabalho realizado no campo da fenotipagem do estresse vegetal usando ML na identificação, classificação, quantificação e predição (ICQP), assim como uma visão geral das questões gerais em

ML para desenvolver uma estratégia para uma aplicação mais ampla e adaptável à agricultura; contribuir para uma estrutura técnica para a aplicação de ML no melhoramento de plantas para resolver problemas práticos, especialmente fenotipagem de estresse de plantas usando imagens digitais; e discutir as vantagens e desvantagens de vários algoritmos de ML na fenotipagem de estresse com o objetivo de permitir uma exploração mais aprofundada dessas ferramentas para facilitar o uso prático no melhoramento de plantas.

O estudo explora as diferentes abordagens de ML em diversos estudos individualmente (tabelas 4.11, 4.12 e 4.13).

Um ingrediente chave para o sucesso da aplicação em grande escala do ML é a integração perfeita da análise de dados no pipeline de coleta de dados e de curadoria. Esta revisão permite que essas equipes forneçam uma linguagem comum de comunicação relacionada às ferramentas de ML.

### 4.33 Estudo EIC8

**Relevância:** Média

O estudo EIC8, intitulado "Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform"[39], de 2016, teve como objetivo estabelecer uma plataforma de fenotipagem de larga escala baseada em um VANTs equipados com um sistema multiespectral de sensores, através da aquisição de dados de imagens de alta resolução, seguido de uma análise de aprendizado de máquina de floresta aleatória para melhorar a eficiência da produção de soja.

Realizado em Urbana, Illinois, EUA, EIC8 utilizou um octocóptero X8 da empresa 3D Robotics. O drone foi equipado com duas câmeras digitais Canon S110 de 12 megapixels, cujas larguras focais foram reguladas para 5.2 mm. Os voos ocorreram a 95 m de altura e 6 m/s de velocidade. As imagens foram obtidas com sobreposição de 88% frontal e 60% lateral. A resolução espacial foi de 3.5 cm/pixel.

Mais de 93% de precisão na previsão de maturidade foi mostrada no modelo de floresta aleatória no teste de seleção genômica, e resultados semelhantes foram validados em um estudo de campo independente (teste de mapeamento de associação aninhada), onde variedades de soja com fundo genético distinto foram cultivadas em diferentes planos.

Com a plataforma de fenotipagem de larga escala e o modelo de floresta aleatória, foi possível alcançar até 63% de correspondência exata entre as classificações tiradas da maneira tradicional e as maturidades previstas; porém é importante notar que erros de previsão e tendências humanas existiam no conjunto de dados de referência. Quando uma diferença de até uma data (aproximadamente três dias corridos) de amostragem é aceita entre as maturidades previstas e registradas, o modelo alcançou uma precisão quase perfeita (> 95%) para os dois testes de campo independentes.

Resultados mostraram a capacidade da plataforma em melhorar a eficiência da criação de soja e sua conveniência e produtividade ao possibilitar diversos

**Tabela 4.11.** Abordagens de ML em Espécies de Plantas para Fenotipagem de Estresse

Aplicação do Algoritmo	Tipo do Algoritmo	Sensor	Espécie	Traços Fenotipados	Tipo de Estresse
Identificação	SVM <sup>a</sup> com kernel linear	Termal; luz visível estéreo	Tomate ( <i>Solanum lycopersicum</i> L.)	Oídio	Doença
Identificação	SAM <sup>b</sup>	Remoto	Beterraba ( <i>Solanum lycopersicum</i> L.)	Heterodera schachtii; Rhizoctonia solani	Doença; peste
Identificação	SVM; GPC <sup>c</sup>	Imagens visíveis e termais	Espinafre ( <i>Spinacia oleracea</i> L.)	Seca	Abiótico
Identificação	Fator de Bayes; DAR	Imagens hiper-espectrais	Cevada ( <i>Hordeum vulgare</i> L.)	Oídio; ferrugem; mancha	Doença
Identificação	SVM	Espec-troscopia por fluorescência	Citrus ( <i>Citrus sinensis</i> (L.) Osbeck)	Huanglongbing (HLB)	Doença
Identificação	OBIA <sup>d</sup>	Imagens RGB e multi-espectrais	Girassol ( <i>Helianthus annuus</i> L.)	Erva daninha	Biótico
Identificação	SVM; kernel linear; kernel quadrático; função de base radial; perceptron multi-camada; kernel polinomial	Imagem RGB	Tomate	Vírus da folha amarela do tomate; doença da folha amarela do tomate	Doença
Identificação	variante de ANN <sup>e</sup>	Imagem RGB	Orquídea ( <i>Phalaenopsis</i> )	Podridão mole bacteriana; podridão negra Phythophthora; mancha marrom bacteriana	Doença
Identificação	SVM	Drone e aeronave	Citrus	Huanglongbing (HLB)	Doença

<sup>a</sup> máquina de vetores de suporte<sup>b</sup> Spectral Angle Mapper<sup>c</sup> Gaussian Processes Classifier<sup>d</sup> Object-based Image Analysis<sup>e</sup> Artificial neural network

**Tabela 4.12.** Abordagens de ML em Espécies de Plantas para Fenotipagem de Estresse

Aplicação do Algoritmo	Tipo do Algoritmo	Sensor	Espécie	Traços Fenotipados	Tipo de Estresse
Identificação	KNN <sup>a</sup> ; análise discriminante quadrática; análise discriminante linear	Espec-trorradiô-metro	Citrus	Huanglongbing (HLB)	Doença
Identificação	SViM	Hiper-espectral	Tomate	Estresse hídrico	Seca
Identificação	Modelo mistura Gaussiana	Imagens RGB	Trigo ( <i>Triticum aestivum</i> L.)	Vírus do mosaico estriado	Doença
Identificação	Variante de SVM	Imagens digitalizadas	Arroz ( <i>Oryza sativa</i> L.)	Estresse de nitrogênio, fósforo e potássio (NPK)	Deficiência de nutriente
Identificação/classificação	HBBE, MLPNNs <sup>b</sup> , LDA <sup>c</sup>	Imagens CCD <sup>d</sup>	Pimenta Chili ( <i>Capsicum annuum</i> L.)	Aflatoxinas	Metabólitos tóxicos
Identificação/classificação	SVM	Refletância hiperespectral	Beterraba	Mancha foliar de Cercospora; ferrugem da beterraba; oídio	Doença
Identificação/classificação	LDA; K-means	Imagens RGB	Trevo ( <i>Trifolium subterraneum</i> L.)	Ozônio	Poluição
Identificação/classificação	SOM <sup>e</sup>	Imagens RGB	Tomate	Oídio	Doença
Identificação/classificação	Classificador bayesiano	Imagens RGB	Tomate	Oídio	Doença
Identificação/classificação	NB <sup>f</sup> ; SL <sup>g</sup> ; LibSVM; LibLINEAR; MLP (BNN); FT <sup>h</sup> ; RF <sup>i</sup> ; J48 <sup>j</sup>	Imagens hiperespectrais	Colza oleaginosa ( <i>Brassica napus</i> L.)	Alternaria alternata, Alternaria brassicae, Alternaria brassicicola, Alternaria dauci	Doença
Classificação	SVM	Imagens RGB	Arabidopsis ( <i>Arabidopsis thaliana</i> L.)	Salmonella	Doença

<sup>a</sup> k-nearest neighbors<sup>b</sup> Multi-Layer Perceptron Neural Networks<sup>c</sup> latent Dirichlet allocation<sup>d</sup> charged coupled device<sup>e</sup> Self-organizing map<sup>f</sup> Naive Bayes<sup>g</sup> logística simples<sup>h</sup> árvores funcionais<sup>i</sup> florestas aleatórias<sup>j</sup> classificador para gerar uma árvore de decisão C4.5 enxertada

**Tabela 4.13.** Abordagens de ML em Espécies de Plantas para Fenotipagem de Estresse

Aplicação do Algoritmo	Tipo do Algoritmo	Sensor	Espécie	Traços Fenotipados	Tipo de Estresse
Classificação	Floresta aleatória e kernel de correspondência espacial SVM	-	-	Larvas da mosca de pedra	Insetos
Classificação	k-NN e classificador bayesiano	Fusão de imagem RGB e multiespectral	Beterraba	Uromyces betae, Cercospora beticola	Doença
Classificação	classificador bayesiano	Imagem RGB	Arabidopsis	Salmonella	Doença
Quantificação	SVM	Imagem RGB e refletância espectral	Tomate	Minador	Inseto
Quantificação	SVM e LDA	Sensor hiperespectral e imagens térmicas	Azeitona	Verticillium dahliae	Doença
Predição	DAR <sup>a</sup>	Imagens hiperespectrais	Cevada	Seca	Abiótico
Predição	SVM; GRNN <sup>b</sup>	Classificação de severidade manual	Arroz	Fungo da brusone do arroz	Doença
Predição	SVM	Imagens hiperespectrais	Cevada	Seca	Abiótico

<sup>a</sup> Dirichlet aggregation regression<sup>b</sup> rede neural de regressão generalizada

estudos de campo em grande escala, muitos dos quais podem ser aplicáveis a outras culturas. Espera-se que o uso de plataformas de sensoriamento remoto para fenotipagem de larga escala reduza o atual desequilíbrio entre fenotipagem e produção de genotipagem, e aumente a eficiência da coleta de dados fenotípicos em programas de melhoramento genético em larga escala.

#### 4.34 Estudo SC08

**Relevância:** Alta

O estudo SC08, intitulado "Automated Ortho-Rectification of UAV-Based Hyperspectral Data over an Agricultural Field Using Frame RGB Imagery"[40], de 2016, procura introduzir uma abordagem automatizada para melhorar a retificação geométrica de imagens hiper-espectrais na presença de dados de navegação de baixa qualidade através da incorporação de imagens de quadros.

SC08 foi efetuado em Lafayette, Indiana, EUA. Foi utilizado um quadricóptero DJI Phantom 2 e uma câmera GoPro. O drone voou a aproximadamente 15 m de altura, movendo-se a 8 m/s com sobreposição de 60%. Os voos resultaram em um GSD de 1.5 cm. Dados hiper-espectrais, por sua vez, foram obtidos a partir de um sistema de varredura eletrônica Headwall Nano-Hyperspec. Para a coleta desses dados, a velocidade utilizada foi de 16 m/s a uma altitude de 120 m. O GSD para essa configuração foi de aproximadamente 5 cm.

Embora a qualidade do ajuste para os parâmetros de transformação manuais seja melhor que a dos automáticos, a abordagem proposta é capaz de melhorar a qualidade das ortofotos hiperespectrais parcialmente retificadas sem a necessidade de intervenção manual. A abordagem automatizada proposta melhorou a qualidade do ajuste de aproximadamente 5 m para quase 0.6 m. A este respeito, deve-se notar que a qualidade de ajuste utilizada é tendenciosa para os parâmetros de transformação manuais.

A abordagem proposta tende, ainda, a mostrar melhor desempenho quando as informações originais de georreferenciamento direto são relativamente precisas. Ou seja, sempre que a qualidade de ajuste antes do refinamento é relativamente alta (isto é, pequeno valor de RMSE), a qualidade de ajuste após o refinamento correspondente é significativamente melhorada.

O número de tie points identificados automaticamente não tem impacto significativo na qualidade do refinamento da ortofotografia hiperespectral. Pode ser visto, a partir da avaliação da precisão da qualidade de ajuste, que o RMSE entre os pontos de empate, usando os parâmetros de transformação estimados, mostrou valores semelhantes, independentemente do número de tie points identificados.

A integração de imagens de varredura eletrônica e de câmera de quadros pode ajudar a mitigar o impacto negativo das informações de georreferenciamento, melhorando a qualidade geométrica das ortofotos hiperespectrais retificadas.

### 4.35 Estudo SCO9

**Relevância:** Alta

O estudo SCO9, intitulado "Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries"[41], de 2016, teve como objetivo primário desenvolver e validar um pipeline para processamento de dados capturados por câmeras digitais de nível de consumidor usando um VANT de baixo custo para avaliar pesquisas baseadas em campo de pequenas parcelas típicas de programas de melhoramento de plantas.

O estudo ocorreu em Ciudad Obregon, Sonora, México. Foram usados dois VANTs: um IRIS+ da empresa 3D Robotics, com uma câmera Canon S100 modificada pela empresa MaxMax para Azul-Verde-NIR, e um gimbal para compensar o movimento; e um drone eBee Ag da empresa senseFly, com uma câmera Airinov MultiSpec 4C, com bandas verde, vermelha, ponta vermelha e infravermelha próxima.

O IRIS+ voou a uma altitude de 30 m e velocidade de 2 m/s, enquanto o eBee Ag voou a 48 m do solo e 10 m/s de velocidade.

Com base na correlação com as leituras espectrais e avaliação da herdabilidade, a Canon S100 teve um desempenho melhor do que a MultiSpec 4C montado no drone de asa fixa, que foi provavelmente o resultado de uma maior resolução do sensor, menor altitude e menor velocidade de deslocamento da Canon S100 no quadróptero IRIS+.

Para gerar ortomosaicos, foram testados os dois métodos de mesclagem: mosaico e média. O ortomosaico gerado pelo método mosaico mostrou uma maior qualidade do que o modo médio. Por outro lado, o modo de mesclagem de mosaico gerou artefatos na imagem, uma vez que usa menos imagens ao selecionar pixels com a menor distância do centro da imagem. Foi examinada a correlação entre os ortomosaicos gerados a partir dessas duas abordagens e os dados do solo e foi determinado que o método de média tem correlação ligeiramente superior (0.68) em comparação com o método de mosaico (0.65).

Foram examinadas três maneiras diferentes de extração de trigo: grade simples, mapa de campo e classificação de imagem. A técnica baseada no mapa de campo se mostrou mais precisa e rápida em comparação com outras técnicas, e teve uma correlação mais alta com os dados de campo. A vantagem desse método é que ele é aplicável a qualquer tipo de cultura, desde que o mapa de campo seja fornecido, e o método é totalmente automatizado em Python.

Com a visão de integrar múltiplas medições extraídas de VANT (altura de plantas, cobertura do solo, etc.) com simulações de crescimento de plantas para maximizar a utilidade biológica dos fenótipos estimados, novos caminhos serão abertos aos criadores para prever o rendimento.

### 4.36 Estudo SCO10

**Relevância:** Extrema

O estudo SCO10, intitulado "Unmanned Aerial Vehicles for High-Throughput Phenotyping and Agronomic Research"[42], de 2016, possui três objetivos principais:

- fornecer dados de imagens de alta resolução e alta qualidade a um grupo diversificado de pesquisadores agrícolas em vários campos e terrenos em uma grande fazenda de pesquisa;
- estabelecer o fluxo de trabalho de coleta e processamento de dados, bem como a comunicação e coordenação entre os especialistas necessários para tal empreendimento;
- desenvolver métodos para criadores de plantas e agrônomos para incorporar dados de sensoriamento remoto coletados pelo drone a fim de melhorar resultados e capacidade de tomada de decisão.

Foram utilizados três drones (dois de asa fixa e um de asa giratória). O **Anaconda** da empresa **ReadyMadeRC** realizou voos a 120 m de altitude e 15 m/s de velocidade, com uma câmera multi-espectral **Sentek GEMS**; o **Lancaster Mark III Rev 3** da **PrecisionHawk** também voou a 120 m, mas sua velocidade oscilou entre 12 e 15 m/s, com duas câmeras (uma por vez) - uma **Nikon J3** com cor verdadeira e uma **Nikon J3** modificada com infravermelho; e o **X88** (asa giratória) da **TurboAce** efetuou os voos a alturas entre 15 e 10 m e 6 m/s, com uma câmera **DJI P3-005 4K**.

Como o estudo utilizou quatro câmeras distintas, foi montada a tabela 4.14 a fim de melhorar a visualização dos dados.

**Tabela 4.14.** Detalhes técnicos do estudo 4.36

	<b>Sentek GEMS</b>	<b>Nikon J3</b>	<b>Nikon J3 modificada</b>	<b>DJI P3-005 4K</b>
Veículo	Anaconda	Lancaster	Lancaster	X88
Altitude de voo (m)	120	120	120	15-20
GSD (cm)	6.5	1.86	3.44	0.8
Velocidade (m/s)	15	12-15	12-15	6

As imagens de VANT não são apenas imagens de sensoriamento remoto com uma resolução espacial mais elevada (mm a cm), os dados de imagem dos drones devem ser manipulados de uma maneira diferente dos dados tradicionais de sensoriamento remoto. Há a necessidade de juntar as imagens para cobrir uma área mais ampla, e, em resoluções tão altas, é necessário garantir que não haverá pixels borrados causados por movimento.

A resolução da câmera e a altura acima do solo limitam o GSD teórico. O tempo mínimo de exposição limita o GSD real ao longo da trajetória de voo,

pois, em pequenos GSDs, a velocidade do veículo aéreo pode cobrir a distância de pixel em menos tempo do que a câmera requer para exposição; isso significa que os pixels podem, teoricamente, ter um GSD pequeno, mas serão efetivamente "espalhados" por uma distância maior. A taxa de quadros da câmera, por sua vez, unida à velocidade do veículo aéreo, limita a quantidade de sobreposição, o que é essencial para criar bons mosaicos. Ou seja, uma câmera ideal teria alta resolução, alta taxa de quadros, e curto tempo de exposição.

É necessário, ainda, que as imagens sejam capturadas o mais perto possível do ponto de *nadir*[10]. Isso pode ser alcançado com a combinação de um veículo aéreo estável e um gimbal para fazer com que a câmera fique apontada para baixo independentemente do comportamento do veículo.

Finalmente, é comum descobrir no final de uma missão de voo que a sobreposição de imagens não era adequada em certas áreas. Um cálculo em tempo real durante o voo da necessidade de visitar parte da trajetória minimizaria a possibilidade de mosaicos ruins causados por sobreposição inadequada de imagens.

#### 4.37 Estudo SCO11

**Relevância:** Média

O estudo SCO11, intitulado "High Throughput Field Phenotyping of Wheat Plant Height and Growth Rate in Field Plot Trials Using UAV Based Remote Sensing"[43], de 2016, visa avaliar quão precisos são os modelos e alturas de culturas geradas quando comparados ao padrão existente na indústria; quão replicável é o método ao longo do ciclo de desenvolvimento das culturas de trigo, particularmente entre os estágios GS30 e GS61 na escala Zadoks (o crescimento pode ser monitorado?); e se esses métodos são aplicáveis em pesquisa de culturas e se oferece uma melhor qualidade de dados em comparação com o método de regra.

SCO11 foi realizado no Centro de Pesquisa Rothamsted, Reino Unido. Foi utilizado o octocóptero *Cinestar*, carregando uma câmera *Sony NEX 7* de 24.3 megapixels. O drone voou a 90 e 40 m e a trajetória buscou assegurar uma sobreposição de 80% frontal e 60% lateral. As imagens obtiveram resolução de 1.4 cm/pixel (para voos de 90 m de altura) e 0.7 cm/pixel (para 40 m).

Para os resultados do VANT, menores altitudes produziram alturas de colheita significativamente mais precisas, graças a maior resolução de solo alcançada a menores altitudes. Houve uma clara vantagem em usar "filtragem de profundidade moderada" durante o processamento para alcançar maior precisão na altura da safra, provavelmente devido à redução na "suavização" do modelo, permitindo que mais das pequenas características da planta de interesse permanecessem durante a etapa de filtragem.

Avaliações de precisão das alturas das culturas coletadas pelo VANT mostraram que o método foi capaz de produzir medidas de altura comparáveis em precisão àquelas medidas pelo manual existente. A alta resolução espacial dos dados derivados do VANT permite avaliar a variabilidade espacial da altura da

cultura tanto na escala de campo como na de plotagem. As campanhas de voo dos VANTs ao longo da temporada permitiram o monitoramento das mudanças na altura das culturas, bem como o cálculo da taxa de crescimento.

A comparação entre alturas de culturas obtidas por VANT e medições terrestres indica consistentes altos níveis de precisão. Os dados produzidos forneceram boa concordância com o procedimento atualmente aplicado de medição manual com uma régua ( $R^2 \geq 0.93$ , Erro Quadrático Médio da Raiz (RMSE)  $\leq 0.077$  m), mas essa abordagem é mais consistente e espacialmente extensa, reduzindo o erro do usuário associado à medição da régua. A avaliação do modelo de um LiDAR terrestre de alta precisão (5 mm) ( $R^2 = 0.97$ , RMSE = 0.027 m) e o melhor modelo de drone ( $R^2 = 0.99$ , RMSE = 0.03 m) mostra a capacidade do sistema de produzir resultados altamente precisos; no entanto, os custos extremamente altos e a baixa eficiência de tempo do LiDAR, devido ao grande número de varreduras individuais necessárias, reduzem seriamente a adequação do LiDAR para esta aplicação.

O drone mostrou uma subestimação das alturas das culturas, porém, no geral, os resultados mostraram uma melhora na precisão em comparação com estudos semelhantes, mesmo quando o método foi aplicado em um número significativamente maior de parcelas experimentais (300).

#### 4.38 Estudo SCD15

**Relevância:** Extrema

O estudo SCD15, intitulado "Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review"[44], de 2015, examina o potencial de usar imagens aéreas de baixa altitude e alta resolução com VANTs para fenotipagem rápida de culturas no campo.

Para isso, SCD15 propõe e avalia os sensores listados nas tabelas 4.15 e 4.16, com suas diferentes aplicações, assim como as safras mostradas na tabela 4.17, na qual são listados alguns parâmetros usados para a obtenção de estimativas de rendimento.

A implementação bem sucedida de drones para fenotipagem de campo depende de dois fatores principais - as características do VANT, como estabilidade, segurança, controle, confiabilidade, posicionamento, autonomia, montagem do sensor e controlador; e as características do sensor, como comprimentos de onda espectrais específicos, resolução, peso, calibração e campo de visão. A operação do VANT é frequentemente limitada pela carga útil do sensor (tamanho/peso), pela altitude de operação (questões regulatórias) e pelo tempo de voo. Uma solução alternativa de tempo de voo seria usar um cabo de alimentação para o drone, o que forneceria uma fonte contínua de energia e também satisfaria os requisitos regulamentares.

**Tabela 4.15.** Diferentes tipos de sensores usados na caracterização de fenótipo de plantas

<b>Tipo de Sensor</b>	<b>Detalhes</b>	<b>Aplicações</b>	<b>Limitações</b>
RGB	Escala de cinza ou imagens coloridas	Propriedades visíveis, defeitos externos, cor, crescimento	Limitado a bandas e propriedades espectrais visuais
Câmera multi-espectral/ infravermelha	Poucas bandas espectrais para cada pixel na região do visível-infravermelho	Múltiplas respostas de plantas à deficiência de nutrientes, estresse hídrico, doenças, etc	Limitado a poucas bandas espectrais
Câmera hiper-espectral	Espectros contínuos ou discretos para cada pixel na região do visível-infravermelho	Estresse da planta, qualidade do produto e controle de segurança	Processamento de imagem é desafiador; e sensores podem ser caros
Sensor termal	Temperatura de cada pixel (para sensor com calibração radiométrica) relacionada a emissões térmicas de infravermelho	Condutância estomática, respostas das plantas ao estresse hídrico e doenças	Condições ambientais afetam o desempenho; diferenças de temperatura muito pequenas não são detectáveis; e câmeras de alta resolução são mais pesadas
Espectrômetro	Espectros de infravermelho visível próximo da média em um determinado campo de visão	Detectar doenças, estresse e respostas das culturas	Contexto, como solo, pode afetar a qualidade dos dados; possibilidades de mistura espectral; mais aplicável para sistemas baseados em terra
Câmera 3D	Deteção baseada em laser infravermelho usando informações de tempo de voo	Atributos físicos, como a altura da planta e a densidade da cobertura	Menores precisões; e aplicações de campo podem ser limitantes

**Tabela 4.16.** Diferentes tipos de sensores usados na caracterização de fenótipo de plantas

<b>Tipo de Sensor</b>	<b>Detalhes</b>	<b>Aplicações</b>	<b>Limitações</b>
Sensor de detecção de luz e alcance	Medidas físicas resultantes do tempo de voo do laser (600–1000 nm)	Estimativas precisas de altura e volume da planta	Sensível a pequenas variações no comprimento do caminho
Sensor de navegação sonora e variação	A propagação de som é usada para detectar objetos com base no tempo de voo	Mapeamento e quantificação dos volumes da copa, controle digital das taxas de aplicação em pulverizadores ou espalhador de adubo	Sensibilidade limitada pela absorção acústica, ruído de fundo, etc; e menor taxa de amostragem do que a detecção baseada em laser

#### 4.39 Estudo SCD16

##### **Relevância:** Média

O estudo SCD16, intitulado "Field-based crop phenotyping: Multispectral aerial imaging for evaluation of winter wheat emergence and spring stand"[45], de 2015, avalia o potencial da tecnologia de sensoriamento remoto de baixa altitude como uma ferramenta de fenotipagem de alta produtividade para avaliação da emergência de trigo de inverno e sobrevivência no inverno (resistência ao inverno) sob condições de campo.

SCD16 foi realizado em Kahlotus, EUA. O estudo contou com um drone HiSystems GmbH e uma câmera digital multiespectral XNiteCanon SX230 NDVI modificada, com bandas verde, azul e infravermelho próximo; e 12.1 megapixels (4000×3000). Durante avaliações preliminares, a altitude de voo foi ajustada usando uma câmera digital simples Sony NEX-5N a fim de estimar a resolução espacial a diferentes altitudes. A Sony possuía 16.1 megapixels com uma resolução de 4912×3264. As imagens foram obtidas a alturas de 100, 75 e 55 m; e resoluções espaciais de 2.3 cm/pixel, 2.0 cm/pixel e 1.4 cm/pixel, respectivamente, para as imagens RGB, e 3.0 cm/pixel, 2.3 cm/pixel e 1.6 cm/pixel nas imagens multi-espectrais.

Uma boa correlação entre a emergência de inverno baseada em imagens aéreas (%) e a medição do solo foi observada com o coeficiente de correlação de Pearson (r) variando de 0.82 a 0.93. Foi observada, ainda, uma alta correlação entre os dados da imagem do solo e dos dados multiespectrais do drone. Da mesma forma, os dados de emergência e suporte de nascente estimados usando imagens aéreas para cada variedade foram calculados e comparados com avaliações de verdade do solo. Uma alta correlação (> 0.92) foi observada entre as estimativas e os dados do solo para as variedades brancas brancas e vermelhas duras.

**Tabela 4.17.** Parâmetros usados para a obtenção de estimativas de rendimento

Saфра	Detalhes de Detecção
Trigo (17 genótipos)	<ul style="list-style-type: none"> <li>– <b>Plataforma:</b> Power glider (L’Avion Jaune); e Pixy (ABS-Aeroligt)</li> <li>– <b>Sensores:</b> Canon EOS350D de três canais; e Sony DSC-F828 de quatro canais com filtro personalizado.</li> <li>– <b>Resolução:</b> 5cm/pixel a 20–100 m</li> <li>– <b>Intervalo de Obtenção das Imagens:</b> 6 voos Fevereiro–Junho</li> <li>– <b>Software de Análise:</b> -</li> </ul>
Arroz	<ul style="list-style-type: none"> <li>– <b>Plataforma:</b> X-Cell Fury 91 (Miniature Aircraft)</li> <li>– <b>Sensores:</b> Tetracam ADC de três canais</li> <li>– <b>Resolução:</b> 0.71 m/pixel a 20 m</li> <li>– <b>Intervalo de Obtenção das Imagens:</b> 65 dias após o plantio</li> <li>– <b>Software de Análise:</b> Pixelwrench</li> </ul>
Batata	<ul style="list-style-type: none"> <li>– <b>Plataforma:</b> Piper Seneca</li> <li>– <b>Sensores:</b> Câmeras Kodak Megaplug 4.2i customizadas para o verde</li> <li>– <b>Resolução:</b> 1 m</li> <li>– <b>Intervalo de Obtenção das Imagens:</b> 3 voos (mensalmente) entre Julho e Agosto</li> <li>– <b>Software de Análise:</b> ERDAS</li> </ul>
Milho	<ul style="list-style-type: none"> <li>– <b>Plataforma:</b> E-Trainer 182 (Graupner GmbH) customizado</li> <li>– <b>Sensores:</b> Espectrômetro monolítico em miniatura MMS1 (Carl Zeiss GmbH)</li> <li>– <b>Resolução:</b> 8–100 m de altitude</li> <li>– <b>Intervalo de Obtenção das Imagens:</b> 3 voos (mensalmente) entre Agosto e Outubro</li> <li>– <b>Software de Análise:</b> ArcGIS (ESRI), SigmaStat 3.5 (Dundas Software, Ltd.)</li> </ul>

#### 4.40 Estudo SCD17

**Relevância:** Baixa

O estudo SCD17, intitulado "Green area index from an unmanned aerial system over wheat and rapeseed crops"[46], de 2014, tem como objetivo desenvolver e avaliar um método de estimativa de índice de área verde (IAV) a partir de medições de refletância de drones no contexto de aplicações agrícolas de precisão, com ênfase em culturas de trigo e colza.

Houve seis áreas de estudo na França: uma em Auzeville, duas em Poitou e duas em Dijon. Foi usado um drone planar de 2 metros de envergadura da empresa **Airinov**, assim como uma câmera patenteada, composta por quatro sensores CMOS e desenvolvida pela mesma empresa. A câmera conta com quatro bandas espectrais (verde, vermelho, red edge e infravermelho próximo). Cada sensor CMOS tem  $752 \times 480$  pixels.

O VANT fez trilhas paralelas a cada 37 m. À altitude típica de 150 m, a resolução espacial foi de aproximadamente 0.15 m com uma faixa transversal de 112 m. Essa configuração resultou em uma sobreposição de 80% entre imagens paralelas, e 66% em imagens transversais. A direção da vista era geralmente próxima do nadir[10], com ângulo zenital máximo próximo a  $30^\circ$ .

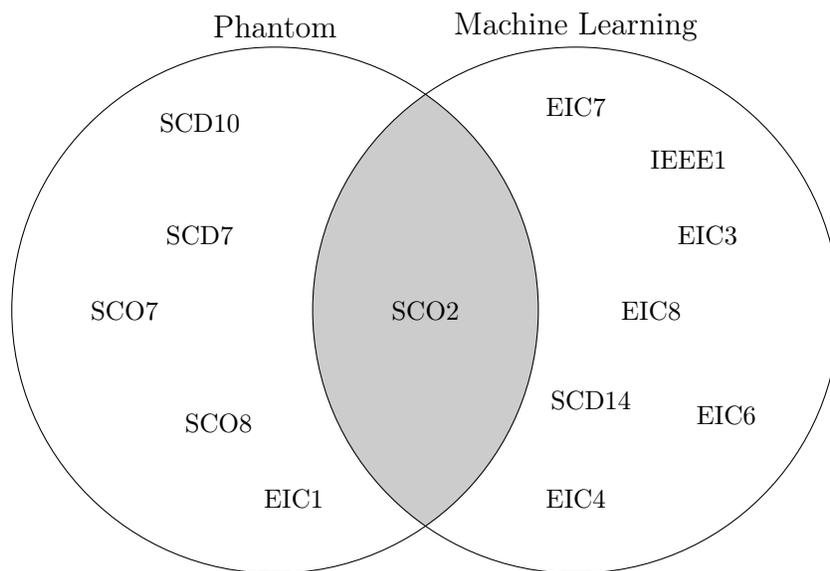
Um estudo dedicado foi realizado para avaliar a precisão absoluta da geolocalização de cada pixel. Os pixels no ortomosaico foram deslocados, em média, por 2 cm na direção norte e 0.6 cm na direção oeste, com um desvio padrão de cerca de 4 cm em cada direção, o que parece ser uma precisão muito boa em relação à resolução espacial de 15 cm.

Como o IAV deve mudar apenas marginalmente dentro de um dia, a estabilidade das estimativas obtidas no mesmo dia em dois voos diferentes precisou ser verificada. Os voos estavam em bom acordo para as funções de custo absoluto e relativo. No entanto, o uso da função de custo relativo,  $J_{rel}$  degradou ligeiramente a consistência entre os voos; principalmente para os maiores valores de IAV. Ademais, as estimativas GAI dos drones estavam em muito boa concordância com as medições no solo.

O erro quadrático médio (EQM), calculado a partir das várias repetições de medições GAI no solo, foi relativamente pequeno para a colza, mas muito maior para as culturas de trigo, devido à maior heterogeneidade das culturas de trigo da amostra. Para IAV maior que 2, o EQM associado a estimativas do drone e de medições do solo geralmente aumentou com o valor do IAV, com uma maior variabilidade entre as unidades elementares de amostragem. De fato, a estimativa do IAV é mais difícil para os maiores valores, devido aos efeitos de saturação.

## 5 Comparação com o Estudo Proposto

O diagrama de Venn representa os estudos que mais condizem com os parâmetros buscados a fim de realizar o estudo proposto. Eles são separados em estudos que usam o drone DJI Phantom e estudos que usam Machine Learning, assim como a intersecção entre esses dois conjuntos para que, assim, a visualização se dê de maneira mais eficiente.



## 6 Documentação da Revisão

O próximo passo, segundo Barbara Kitchenham[1], é a distribuição e disseminação desse mapeamento sistemático às partes interessadas para que as informações aqui descritas possam ser utilizadas em novos estudos, assim como auxiliar pesquisadores e melhoristas quanto à utilização de drones, possivelmente seguindo os parâmetros apresentados.

## Referências

1. Barbara Kitchenham. Guidelines for performing systematic literature reviews in software engineering. *EBSE Technical Report*, 2007-01, 2007.
2. Mendeley. <https://www.mendeley.com/>. [Acesso em: 8 de Agosto de 2018].
3. Antonius G.T. Schut, Pierre C.Sibiry Traore, Xavier Blaes, and Rolf A. de By. Assessing yield and fertilizer response in heterogeneous smallholder fields with UAVs and satellites. *Field Crops Research*, 221(June 2017):98–107, 2018.
4. R. Ballesteros, J.F. Ortega, D. Hernandez, A. del Campo, and M.A. Moreno. Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. *International Journal of Applied Earth Observation and Geoinformation*, 72(May):66–75, 2018.
5. Omar Vergara-Díaz, Mainassara A. Zaman-Allah, Benhildah Masuka, Alberto Hornero, Pablo Zarco-Tejada, Boddupalli M. Prasanna, Jill E. Cairns, and José L. Araus. A novel remote sensing approach for prediction of maize yield under different conditions of nitrogen fertilization. *Frontiers in Plant Science*, 7:666, 2016.
6. Chinsu Lin, Shih Yu Chen, Chia Chun Chen, and Chia Huei Tai. Detecting newly grown tree leaves from unmanned-aerial-vehicle images using hyperspectral target detection techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, 142(May):174–189, 2018.
7. Pengcheng Hu, Scott C. Chapman, Xuemin Wang, Andries Potgieter, Tao Duan, David Jordan, Yan Guo, and Bangyou Zheng. Estimation of plant height using a high throughput phenotyping platform based on unmanned aerial vehicle and self-calibration: Example for sorghum breeding. *European Journal of Agronomy*, 95(January):24–32, 2018.
8. Sindhuja Sankaran, Jianfeng Zhou, Lav R. Khot, Jennifer J. Trapp, Eninka Mndolwa, and Phillip N. Miklas. High-throughput field phenotyping in dry bean using small unmanned aerial vehicle based multispectral imagery. *Computers and Electronics in Agriculture*, 151:84–92, aug 2018.
9. Peter P.J. Roosjen, Benjamin Brede, Juha M. Suomalainen, Harm M. Bartholomeus, Lammert Kooistra, and Jan G.P.W. Clevers. Improved estimation of leaf area index and leaf chlorophyll content of a potato crop using multi-angle spectral data – potential of unmanned aerial vehicle imagery. *International Journal of Applied Earth Observation and Geoinformation*, 66(July 2017):14–26, 2018.
10. Nadir. <https://en.wikipedia.org/wiki/Nadir>. [Acesso em: 21 de Agosto de 2018].
11. L. Malambo, S. C. Popescu, S. C. Murray, E. Putman, N. A. Pugh, D. W. Horne, G. Richardson, R. Sheridan, W. L. Rooney, R. Avant, M. Vidrine, B. McCutchen, D. Baltensperger, and M. Bishop. Multitemporal field-based plant height estimation using 3D point clouds generated from small unmanned aerial systems high-resolution imagery. *International Journal of Applied Earth Observation and Geoinformation*, 64(August 2017):31–42, 2018.
12. Helge Aasen and Andreas Bolten. Multi-temporal high-resolution imaging spectroscopy with hyperspectral 2D imagers – From theory to application. *Remote Sensing of Environment*, 205(December 2017):374–389, 2018.
13. Melinda Pap and Sandor Kiraly. Comparison of segmentation methods on images of energy plants obtained by UAVs. *2018 IEEE International Conference on Future IoT Technologies, Future IoT 2018*, 2018-Janua:1–8, 2018.
14. Muhammad Adeel Hassan, Mengjiao Yang, Awais Rasheed, Xiuliang Jin, Xianchun Xia, Yonggui Xiao, and Zhonghu He. Time-series multispectral indices from unmanned aerial vehicle imagery reveal senescence rate in bread wheat. *Remote Sensing*, 10(6), 2018.

15. Thomas Moeckel, Supriya Dayananda, Rama Rao Nidamanuri, Sunil Nautiyal, Nagaraju Hanumaiah, Andreas Buerkert, and Michael Wachendorf. Estimation of vegetable crop parameter by multi-temporal UAV-borne images. *Remote Sensing*, 10(5):1–18, 2018.
16. Lukas Roth, Helge Aasen, Achim Walter, and Frank Liebisch. Extracting leaf area index using viewing geometry effects—A new perspective on high-resolution unmanned aerial system photography. *ISPRS Journal of Photogrammetry and Remote Sensing*, 141:161–175, 2018.
17. Zohaib Khan, Joshua Chopin, Jinhai Cai, Vahid Rahimi Eichi, Stephan Haeefele, and Stanley J. Miklavcic. Quantitative estimation of wheat phenotyping traits using ground and aerial imagery. *Remote Sensing*, 10(6):1–19, 2018.
18. Yuhao Chen, Javier Ribera, Christopher Boomsma, and Edward Delp. Locating Crop Plant Centers from UAV-Based RGB Imagery. *Proceedings - 2017 IEEE International Conference on Computer Vision Workshops, ICCVW 2017*, 2018-Janua:2030–2037, 2018.
19. Adrian Gracia-Romero, Omar Vergara-Díaz, Christian Thierfelder, Jill E. Cairns, Shawn C. Kefauver, and José L. Araus. Phenotyping conservation agriculture management effects on ground and aerial remote sensing assessments of maize hybrids performance in Zimbabwe. *Remote Sensing*, 10(2):1–21, 2018.
20. Jinha Jung, Murilo Maeda, Anjin Chang, Juan Landivar, Junho Yeom, and Joshua McGinty. Unmanned aerial system assisted framework for the selection of high yielding cotton genotypes. *Computers and Electronics in Agriculture*, 152(February):74–81, 2018.
21. Andres Patrignani and Tyson E. Ochsner. Canopeo: A powerful new tool for measuring fractional green canopy cover. *Agronomy Journal*, 107(6):2312–2320, 2015.
22. T. Duan, S. C. Chapman, Y. Guo, and B. Zheng. Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle. *Field Crops Research*, 210(March):71–80, 2017.
23. Ingunn Burud, Gunnar Lange, Morten Lillemo, Eivind Bleken, Lars Grimstad, and Pål Johan From. Exploring Robots and UAVs as Phenotyping Tools in Plant Breeding. *IFAC-PapersOnLine*, 50(1):11479–11484, 2017.
24. Xiuliang Jin, Shouyang Liu, Frédéric Baret, Matthieu Hemerlé, and Alexis Comar. Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment*, 198:105–114, 2017.
25. Maitiniyazi Maimaitijiang, Abduwasit Ghulam, Paheding Sidike, Sean Hartling, Matthew Maimaitiyiming, Kyle Peterson, Ethan Shavers, Jack Fishman, Jim Peterson, Suhas Kadam, Joel Burken, and Felix Fritschi. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 134:43–58, dec 2017.
26. Kyosuke Yamamoto, Takashi Togami, and Norio Yamaguchi. Super-resolution of plant disease images for the acceleration of image-based phenotyping and vigor diagnosis in agriculture. *Sensors (Switzerland)*, 17(11), nov 2017.
27. Yuhao Chen, Javier Ribera, Christopher Boomsma, and Edward J Delp. PLANT LEAF SEGMENTATION FOR ESTIMATING PHENOTYPIC TRAITS Video and Image Processing Laboratory ( VIPER ), Purdue University , West Lafayette , Indiana , USA. pages 3884–3888, 2017.
28. Ayman Habib, Weifeng Xiong, Fangning He, Hsiuhan Lexie Yang, and Melba Crawford. Improving Orthorectification of UAV-Based Push-Broom Scanner Imagery

- Using Derived Orthophotos from Frame Cameras. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(1):262–276, 2017.
29. Zhou Zhang, Ali Masjedi, Jieqiong Zhao, and Melba M. Crawford. Prediction of sorghum biomass based on image based features derived from time series of UAV images. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2017-July:6154–6157, dec 2017.
  30. Guijun Yang, Changchun Li, Yanjie Wang, Huanhuan Yuan, Haikuan Feng, Bo Xu, and Xiaodong Yang. The DOM generation and precise radiometric calibration of a UAV-mounted miniature snapshot hyperspectral imager. *Remote Sensing*, 9(7):1–21, 2017.
  31. David Anthony and Carrick Detweiler. UAV Localization in Row Crops. *Journal of Field Robotics*, 34(7):1275–1296, 2017.
  32. A. Burkart, V. L. Hecht, T. Kraska, and U. Rascher. Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution. *Precision Agriculture*, 19(1):1–13, 2017.
  33. Friederike Gnädinger and Urs Schmidhalter. Digital counts of maize plants by Unmanned Aerial Vehicles (UAVs). *Remote Sensing*, 9(6), 2017.
  34. decorrstretch function. <https://goo.gl/nCgVyn>. [Acesso em: 30 de Agosto de 2018].
  35. Aaron Patrick and Changying Li. High throughput phenotyping of blueberry bush morphological traits using unmanned aerial systems. *Remote Sensing*, 9(12), 2017.
  36. Ryo Sugiura, Shogo Tsuda, Seiji Tamiya, Atsushi Itoh, Kentaro Nishiwaki, Noriyuki Murakami, Yukinori Shibuya, Masayuki Hirafuji, and Stephen Nuske. Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*, 148:1–10, aug 2016.
  37. Jianfeng Zhou, Lav R. Khot, Haitham Y. Bahlol, Rick Boydston, and Phillip N. Miklas. Evaluation of ground, proximal and aerial remote sensing technologies for crop stress monitoring. *IFAC-PapersOnLine*, 49(16):22–26, 2016.
  38. Arti Singh, Baskar Ganapathysubramanian, Asheesh Kumar Singh, and Soumik Sarkar. Machine Learning for High-Throughput Stress Phenotyping in Plants. *Trends in Plant Science*, 21(2):110–124, 2016.
  39. Neil Yu, Liujun Li, Nathan Schmitz, Lei F. Tian, Jonathan A. Greenberg, and Brian W. Diers. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sensing of Environment*, 187:91–101, dec 2016.
  40. Ayman Habib, Youkyung Han, Weifeng Xiong, Fangning He, Zhou Zhang, and Melba Crawford. Automated ortho-rectification of UAV-based hyperspectral data over an agricultural field using frame RGB imagery. *Remote Sensing*, 8(10):1–22, 2016.
  41. Atena Haghhighattalab, Lorena González Pérez, Suchismita Mondal, Daljit Singh, Dale Schinostock, Jessica Rutkoski, Ivan Ortiz-Monasterio, Ravi Prakash Singh, Douglas Goodin, and Jesse Poland. Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries. *Plant Methods*, 12(1):1–15, 2016.
  42. Yeyin Shi, J. Alex Thomasson, Seth C. Murray, N. Ace Pugh, William L. Rooney, Sanaz Shafian, Nithya Rajan, Gregory Rouze, Cristine L. S. Morgan, Haly L. Neely, Aman Rana, Muthu V. Bagavathiannan, James Henrickson, Ezekiel Bowden, John Valasek, Jeff Olsenholler, Michael P. Bishop, Ryan Sheridan, Eric B. Putman, Sorin Popescu, Travis Burks, Dale Cope, Amir Ibrahim, Billy F. McCutchen, David D. Baltensperger, Robert V. Avant Jr, Misty Vidrine, and Chenghai Yang. Unmanned

- Aerial Vehicles for High- Throughput Phenotyping and Agronomic Research. *PLoS ONE*, c:1–26, 2016.
43. Fenner H. Holman, Andrew B. Riche, Adam Michalski, March Castle, Martin J. Wooster, and Malcolm J. Hawkesford. High throughput field phenotyping of wheat plant height and growth rate in field plot trials using UAV based remote sensing. *Remote Sensing*, 8(12), 2016.
  44. Sindhuja Sankaran, Lav R. Khot, Carlos Zúñiga Espinoza, Sanaz Jarolmasjed, Vidyasagar R. Sathuvalli, George J. Vandemark, Phillip N. Miklas, Arron H. Carter, Michael O. Pumphrey, Richard R.N. Knowles, and Mark J. Pavek. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*, 70:112–123, 2015.
  45. Sindhuja Sankaran, Lav R. Khot, and Arron H. Carter. Field-based crop phenotyping: Multispectral aerial imaging for evaluation of winter wheat emergence and spring stand. *Computers and Electronics in Agriculture*, 118:372–379, oct 2015.
  46. Alexandre Verger, Nathalie Vigneau, Corentin Chéron, Jean Marc Gilliot, Alexis Comar, and Frédéric Baret. Green area index from an unmanned aerial system over wheat and rapeseed crops. *Remote Sensing of Environment*, 152:654–664, 2014.