

**Um pacote computacional para determinação por imagem de  
parâmetros de pulverização agrícola sobre papéis hidrossensíveis**

**Wilhan Valasco dos Santos**  
Eng. Agrônomo

**WILHAN VALASCO DOS SANTOS**

**UM PACOTE COMPUTACIONAL PARA DETERMINAÇÃO POR IMAGEM DE  
PARÂMETROS DE PULVERIZAÇÃO AGRÍCOLA SOBRE PAPÉIS  
HIDROSSENSÍVEIS**

Orientador: Prof. Dr. Anderson Rodrigo da Silva

Dissertação apresentada ao Instituto Federal Goiano – Campus Urutaí, como parte das exigências do Programa de Pós-Graduação em Proteção de Plantas para obtenção do título de MESTRE.

Urutaí – GO  
2022

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

VW678p Valasco, Wilhan  
Um pacote computacional para determinação por  
imagem de parâmetros de pulverização agrícola sobre  
papéis hidrossensíveis / Wilhan Valasco; orientador  
Anderson Rodrigo. -- Urutaí, 2022.  
49 p.

Dissertação (Mestrado em Mestrado Profissional em  
Proteção de Plantas) -- Instituto Federal Goiano,  
Campus Urutaí, 2022.

1. Pacote hydropaper. 2. Tecnologia de aplicação.  
3. Deposição de gotas. 4. Rede neural.. I. Rodrigo,  
Anderson, orient. II. Título.

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

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

### IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- |  |   |
|--|---|
| <input type="checkbox"/> Tese (doutorado)                  | <input type="checkbox"/> Artigo científico              |
| <input checked="" type="checkbox"/> Dissertação (mestrado) | <input type="checkbox"/> Capítulo de livro              |
| <input type="checkbox"/> Monografia (especialização)       | <input type="checkbox"/> Livro                          |
| <input type="checkbox"/> TCC (graduação)                   | <input type="checkbox"/> Trabalho apresentado em evento |

Produto técnico e educacional - Tipo:

Nome completo do autor:

Wilhan Valasco dos Santos

Matrícula:

2020101330540237

Título do trabalho:

Um pacote computacional para determinação por imagem de parâmetros de pulverização agrícola sobre papéis hidrofóbicos

### RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial:  Não  Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIIF Goiano: 12 / 05 / 2022

O documento está sujeito a registro de patente?  Sim  Não

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

### DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:


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

Urutá

Local

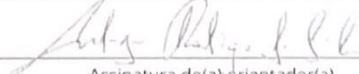
12 / 05 / 2022

Data



Assinatura do autor e/ou detentor dos direitos autorais

Ciente e de acordo:



Assinatura do(a) orientador(a)



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

Ata nº 22/2022 - CREPG-UR/DPGPI-UR/CMPURT/IFGOIANO

**PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO**  
**ATA DE DEFESA**

Aos vinte e dois dias do mês de abril do ano de dois mil e vinte e dois, às nove horas e trinta minutos, reuniram-se os componentes da banca examinadora em sessão pública realizada por videoconferência, para procederem a avaliação da defesa de dissertação em nível de mestrado, de autoria de **Wilhan Valasco dos Santos**, discente do **Programa de Pós-Graduação em Proteção de Plantas do Instituto Federal Goiano - Campus Urutaí**, com trabalho intitulado "Um pacote computacional para determinação por imagem de parâmetros de pulverização agrícola sobre papéis hidrossensíveis". A sessão foi aberta pela presidente da banca examinadora, **Prof. Dr. Anderson Rodrigo da Silva**, que fez a apresentação formal dos membros da banca. A palavra, a seguir, foi concedida ao autor da dissertação para, em 30 dissertação foi ( X ) **APROVADA** ( ) **REPROVADA**, considerando-se integralmente cumprido este requisito para fins de obtenção do título de **MESTRE EM PROTEÇÃO DE PLANTAS**, na área de concentração em **Fitossanidade**, pelo Instituto Federal Goiano - Campus Urutaí. A conclusão do curso dar-se-á quando do depósito versão definitiva da dissertação com as devidas correções no Repositório Institucional do IF Goiano (RIIF). Assim sendo, a defesa perderá a validade se não cumprida essa condição em até **60 (sessenta) dias** a contar da data da defesa. A banca examinadora recomendou a publicação de artigo científico oriundos dessa dissertação em periódicos após procedida as modificações sugeridas, bem como a publicação da biblioteca computacional desenvolvida. Cumpridas as formalidades da pauta, a presidência da banca encerrou esta sessão de defesa de dissertação de mestrado, e para constar, foi lavrada a presente Ata, que, após lida e achada conforme, será assinada eletronicamente pelos membros da banca examinadora.

Membros da Banca Examinadora:

<b>Nome</b>	<b>Instituição</b>	<b>Situação no Programa</b>
Prof. Dr. Anderson Rodrigo da Silva	IF Goiano- Urutaí	Campus Presidente
Dr. Paulo Henrique N. de Souza	Fundação MT	Membro externo
Prof. Dr. Marco Antonio Moreira de Freitas	IF Goiano- Urutaí	Campus Membro interno

Documento assinado eletronicamente por:

- Paulo Henrique Nascimento de Souza, Paulo Henrique Nascimento de Souza - 142335 - Analista de estudos de mercado - Instituto Federal Goiano (1), em 24/04/2022 09:51:35.
- Marco Antonio Moreira de Freitas, COORDENADOR DE CURSO - FUC1 - CCMPP-URT, em 24/04/2022 08:44:49.
- Anderson Rodrigo da Silva, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 22/04/2022 13:02:57.

Este documento foi emitido pelo SUAP em 22/04/2022. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 381093

Código de Autenticação: 4031b16dce



INSTITUTO FEDERAL GOIANO  
Campus Urutaí  
Rodovia Geraldo Silva Nascimento, Km 2,5, Zona Rural, None, URUTAI / GO, CEP 75790-000  
(64) 3465-1900

## **AGRADECIMENTOS**

Queria agradecer primeiramente a Deus, por ter me dado saúde, força e sabedoria para buscar meus objetivos.

À minha família, em especial, meu pai José Pedro e minha mãe Alzenir Valasco, meu irmão Pedro Valasco e minha namorada Erika Rodrigues, por toda a ajuda, compreensão e palavras de incentivo durante esta caminhada.

Aos meus professores, especialmente ao Prof. Anderson R. Silva que me orientou desde a graduação, sempre presente, prestativo e paciente a passar suas experiências e conhecimentos no papel de orientador.

Ao meu amigo Walter Baida, por me apoiar e auxiliar em todas as fases do projeto, se tornando uma peça ímpar no meu processo de formação.

A SmartBredder nas pessoas de Cristiano Fagundes, Donavan Rodeiro e Éder Gigliotti, por sempre apoiar e incentivar a formação e capacitação de pessoas dentro da companhia.

A todos aqui citados, o meu muito obrigado e que Deus abençoe imensamente cada um de vocês.

## SUMÁRIO

LISTA DE FIGURAS .....	viii
LISTA DE TABELAS .....	ix
RESUMO .....	x
ABSTRACT .....	xi
1. INTRODUÇÃO.....	12
2. OBJETIVO.....	14
3. MATERIAL E MÉTODOS.....	15
3.1. Captura de imagens.....	15
3.2. Pré-processamento das imagens: detecção.....	16
3.3. Processamento das imagens.....	17
3.4. Índices de cor.....	18
3.5. Métodos de segmentação.....	19
3.6. Estimação dos parâmetros de pulverização.....	21
3.7. Validação.....	25
3.8. Computação.....	26
4. RESULTADOS.....	27
4.1. Detector de papel hidrossensível.....	27
4.2. Imagens-teste de campo.....	29
4.3. Imagens-teste de laboratório.....	35
4.4. Validação.....	42
4.5. Características do pacote.....	44
5. CONCLUSÕES.....	47
REFERÊNCIAS.....	48



## LISTA DE FIGURAS

FIGURA 1 - (A) Imagem capturada em campo cultivado com milho; (B) Imagem capturada em laboratório.....	11
FIGURA 2 - Ilustração de pontos de interesse (papel hidrossensível) identificados pelo descritor SURF em imagem capturada a campo.....	13
FIGURA 3 - (A) Imagem do papel em campo e recortado pelo descritor SURF, (B) máscara binária resultante de segmentação.....	14
FIGURA 4 - Ilustração de rede neural com duas camadas ocultas.....	16
FIGURA 5. Visão geral esquemática do algoritmo de inundação para o método de watershad.....	17
FIGURA 6 - Deposição manual do volume de calda no papel hidrossensível para validação cruzada.....	22
FIGURA 7 - Performance do descritor SURF (Speeded Up Robust Features) para localização do papel hidrossensível em imagens tiradas em condições de campo (iluminação natural).....	24
FIGURA 8 - (À esquerda) Enquadramento adequado do papel na tela do aparelho de captura em campo; (à direita) Enquadramento incorreto do papel na tela do aparelho de captura em campo.....	24
FIGURA 9 - A) Imagem capturada no campo, B) Recorte do papel pelo descritor SURF da imagem capturada no campo, C) Imagem capturado no laboratório.....	38
FIGURA 10 - Processamento do papel hidrossensível com o hydropaper na validação. A) Papel hidrossensível ao campo, B) Identificação do papel hidrossensível com o descritor surf, C) Recorte do papel hidrossensível com o descritor surf, D) Identificação das gotas com o hydropaper.....	39
FIGURA 11 - Gradiente de acurácia (a esquerda) durante o treinamento de parâmetros ( <i>hidden units, decay</i> ) da rede neural obtida (3-18-3, a direita).....	40

## LISTA DE TABELAS

TABELA 1 - Métodos de segmentação de imagens obtidas em dois ambientes: campo (iluminação natural) e laboratório (iluminação artificial).....	14
TABELA 2 - Parâmetros de pulverização.....	17
TABELA 3 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável número de gotas.....	24
TABELA 4 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável densidade de gotas (gotas/cm <sup>2</sup> ).....	25
TABELA 5 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável diâmetro mediando volumétrico (DMV) (µm).....	26
TABELA 6 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável menor gota (µm).....	27
TABELA 7 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável maior gota (µm).....	28
TABELA 8 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável amplitude relativa.....	29
TABELA 9 - Coeficiente de correlação do método de segmentação com os softwares de referência para imagens capturadas em campo.....	30
TABELA 10 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável número de gotas.....	30
TABELA 11 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável densidade (gotas/cm <sup>2</sup> ).....	31
TABELA 12 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável diâmetro mediano volumétrico (DMV) (µm).....	32
TABELA 13 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável menor gota (µm).....	33
TABELA 14 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável maior gota (µm).....	34
TABELA 15 - Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável amplitude relativa.....	35
TABELA 16 - Correlação método vs referência para imagens capturadas em laboratório.....	36
TABELA 17 - Validação cruzada entre o hydropaper (Redes Neurais) e as referências DropScop e Gotas.....	38

# Um pacote computacional para determinação por imagem de parâmetros de pulverização agrícola sobre papéis hidrossensíveis

## RESUMO

Para avaliar apropriadamente a qualidade da pulverização agrícola, é necessário estimar parâmetros obtidos através de análises de papéis hidrossensíveis, como densidade e diâmetro de gotas. A análise por software é eficiente, porém em geral limitada pelo manuseio dos papéis para digitalização, alta umidade do ar, luminosidade e identificação das menores gotas. Com este trabalho foi desenvolvido um pacote computacional em linguagem R (livre) para análise otimizada de papéis hidrossensíveis, que permite o processamento de imagens dos papéis capturadas a campo. Foram realizados testes comparativos de performance do pacote com sistema disponível no mercado. As imagens-teste foram capturadas em uma área cultivada com milho, distribuindo uniformemente 38 papéis hidrossensíveis em folhas das plantas e posteriormente realizada pulverização manual com pulverizador a CO<sub>2</sub>. Os papéis foram também levados para laboratório para captura de imagens em condições de iluminação artificial controlada. Para imagens de campo, o pacote dispõe de um detector automático de papel hidrossensível. Para estimação dos parâmetros de pulverização, foram realizados testes com diferentes métodos de segmentação (Hue, ExB+Otsu, ExB+Threshold Adaptativo e Rede Neural Artificial). A rede neural promoveu valores próximos ao software tomado como referência, sendo que na validação cruzada apresentou 50% de exatidão nas análises contra 10% do software referência, mostrando robustez às variações nas imagens de campo e laboratório. O pacote está disponível em: <https://arsilva87.github.io/hydropaper>

**PALAVRAS-CHAVES:** Pacote hydropaper; tecnologia de aplicação; deposição de gotas; rede neural.

## **A computational package for image determination of agricultural spray parameters on water-sensitive papers**

### **ABSTRACT**

To properly assess the quality of agricultural spraying, it is necessary to estimate parameters obtained through analysis of water-sensitive papers, such as droplet density and diameter. Software analysis is efficient, but generally limited by the handling of paper for scanning, high air humidity, luminosity and identification of the smallest droplets. With this work, a computational package in R language (free) was developed for the optimized analysis of water-sensitive papers, which allows the processing of images of the papers captured in the field. Comparative tests of the package's performance with the system available on the market were carried out. The test images were captured in an area cultivated with corn, uniformly distributing 38 water-sensitive papers on the leaves of the plants and then manually sprayed with a CO<sub>2</sub> sprayer. The papers were also taken to the laboratory to capture images under controlled artificial lighting conditions. For field imaging, the package has an automatic water-sensitive paper detector. To estimate the spray parameters, tests were performed with different segmentation methods (Hue, ExB+Otsu, ExB+Adaptive Threshold and Artificial Neural Network). The neural network promoted values close to the software taken as a reference, and in the cross-validation it presented 50% accuracy against 10% of the reference, showing robustness to variations in the field and laboratory images. The package is available from: <https://arsilva87.github.io/hydropaper>

**KEYWORDS:** Package hydropaper; application technology; droplet deposition; neural network

## 1. INTRODUÇÃO

O ramo da tecnologia de aplicação de produtos fitossanitários busca promover aplicações de menor volume, maior conservação ambiental, aumento da eficiência e redução do custo operacional (BAESSO et al., 2014). Para que tais metas sejam atingidas, é necessário, além da escolha apropriada do pulverizador e das pontas de pulverização, sua correta regulagem para cada tipo de produto, bem como o acompanhamento da aplicação e a avaliação do processo de pulverização (ALVES, 2020).

Para avaliar a qualidade da pulverização, parâmetros como diâmetro mediano volumétrico e densidade de gotas são utilizados, sendo também úteis para selecionar o tipo de ponta de pulverização que melhor se adequa ao tamanho de gota desejado (fina, média ou grossa) para cada tipo de produto (defensivos de contato/sistêmicos). As estimativas desses parâmetros são obtidas através de análises de papéis hidrossensíveis (RAMOS et al., 2010; CARVALHO et al., 2017; GODINHO JÚNIOR et al., 2017b).

Os papéis hidrossensíveis podem ser analisados visualmente por meio de um gabarito e lupa ou com o auxílio de software baseados em análise de imagens (GARCIA et al., 2004). No entanto, sua análise apresenta algumas limitações, como a dificuldade operacional para analisá-los manualmente e a sensibilidade a ambientes de alta umidade (CUNHA et al., 2013). A análise visual, além de demandar tempo, é um processo desgastante, dado o número elevado de gotículas, sendo altamente suscetível a erros.

A análise por software, por outro lado, é mais eficiente. Porém, também possui suas limitações, sendo dificultada quando existe a necessidade de manuseio dos papéis para digitalização, especialmente em condições de umidade do ar elevada e manuseio sem luvas especiais. Além disso, existe certa limitação geral desses softwares em termos de variação de luminosidade das imagens e medição de gotas com diâmetro inferior a 50 µm (CUNHA et al., 2013; OLIVEIRA et al., 2018).

Sistemas computacionais de análise de imagens foram desenvolvidos para caracterizar e quantificar a deposição de gotas, agilizando o processo de análise com maior precisão (CUNHA et al., 2013; FERGUSON et al., 2016b). São exemplos o software Gotas® (EMBRAPA, 2000), DepositScan® (ZHU et al., 2011), Conta-gotas® (FAVERO et al., 2001), Quant® (LIBERATO, 2003), DropScan® (Leon Sistemas), DropLeaf® (BRANDOLI et al, 2021) e o DropScope® (CHAIM et al., 2006; CUNHA et al., 2020, SPRAYX, 2021). Além desses, outras aplicações de uso geral, como o ImageJ (SCHNEIDER et al., 2012), podem ser configurados para análise dos papéis hidrossensíveis.

Ao analisar a eficiência de alguns destes softwares, foi constatado que amostras com índices de cobertura superiores a 20% não são confiáveis devido ao grande número de gotas que se sobrepõem, tornando a medição da cobertura de alguns alvos imprecisa (ZHU et al., 2011; FOX et al., 2003). Cunha et al. (2012) relata que um dos principais fatores da subestimação do número de gotas depositadas se dá devido ao toque das manchas e a sua sobreposição.

Todavia, busca-se softwares que otimizem o processo de análise, entregando exatidão nos resultados e proporcionando um diferencial na logística operacional além de não exigir equipamentos auxiliares durante a coleta.

Com o avanço da pesquisa agrícola aplicada, percebe-se um grande volume de ensaios conduzidos a campo para atender especificidades locais ou regionais de aplicação de produtos fitossanitários. Decorre disso que a análise usual de papéis hidrossensíveis pode se tornar ineficiente devido a contato exigido com os papéis que possibilita erros experimentais e o tempo elevado para análise dos papéis que pode propiciar alterações indesejadas na tonalidade das gotas.


## **2. OBJETIVO**

Desenvolver e apresentar um pacote computacional em linguagem R (livre) para análise otimizada de papéis hidrossensíveis, que permita o processamento de imagens tomadas a campo.

### 3. MATERIAL E MÉTODOS

#### 3.1. Captura de imagens

Para desenvolvimento dos códigos computacionais, imagens-teste (Figura 1) foram capturadas nas instalações da Universidade Federal de Goiás – Campus Samambaia, Avenida, Esperança, s/n – Chácara de Recreio Samambaia, Goiânia (16° 36' 25,553" S, 49° 15' 33,575" O), em área de 120 m<sup>2</sup> cultivada com milho. Foi utilizado um pulverizador manual de CO<sub>2</sub> com barra de 2,5 m, com seis bicos de pulverização com jato do tipo leque, numa velocidade de pulverização 1 m s<sup>-1</sup> e vazão de 200 L ha<sup>-1</sup>. A aplicação pós-emergencial foi realizada quando as plantas estavam em estágio V3, às 13:15 h do dia 23 de novembro de 2021 com umidade relativa do ar 55,38%, velocidade do vento 1,53 m/s e temperatura 30,36 °. O produto comercial aplicado foi PRIMÓLEO, tendo atrazina como ingrediente ativo.



**Figura 1.** (A) Imagem capturada em campo cultivado com milho; (B) Imagem capturada em laboratório.

Imediatamente antes da pulverização, foram utilizados 38 papéis hidrossensíveis com dimensão de 76x26 mm (Syngenta SYN7626), peso de 0,04 kg e coloração amarela, devidamente presos por papel adesivo na face inferior sobre a folha mais horizontal das plantas. Os papéis foram dispostos uniformemente em toda a área.

As imagens foram capturadas em campo, a pleno sol (Figura 1A), e em laboratório (Figura 1B), isto é, sob luz artificial, sobre fundo branco, com uma câmera digital Canon PowerShot SX530 HS (RGB – Red, Green, Blue) de resolução óptica de 4608 x 2592 pixels.



Para fins de comparação e validação dos parâmetros, os papéis foram também analisados no sistema Dropscope® (SPRAYX, 2021) e Gotas (EMBRAPA, 2000) logo após a retirada.

### 3.2. Pré-processamento das imagens: detecção


O pré-processamento de imagens tomadas em campo inicia-se com a identificação da localização do papel hidrossensível (papel) e a parte de não interesse (*background*) da imagem, para análise específica da parte de interesse (papel). Para identificação da área de interesse, isto é, para a detecção e localização do papel na imagem foi utilizado o algoritmo SURF - *Speeded Up Robust Features* (BAY et al., 2006, 2008) que é baseado no SIFT - *Scale-invariant feature transform* (LOWE, 1999), porém com melhor performance quanto ao tempo de execução.

A detecção dos pontos de interesse do SURF se baseia na matriz Hessiana (1) e utiliza uma aproximação básica. O descritor descreve a resposta do *wavelet Haar* dentro das regiões vizinhas do ponto de interesse  $xy$  (BAY et al., 2008).

$$H(x, y, \sigma) = \begin{bmatrix} L_{xx}(x, y, \sigma) & L_{xy}(x, y, \sigma) \\ L_{xy}(x, y, \sigma) & L_{yy}(x, y, \sigma) \end{bmatrix} \quad (1)$$

em que  $L_{xx}(x, y, \sigma)$  representa a convolução da derivada parcial de segunda ordem da Gaussiana na imagem  $I$  no ponto  $(x, y)$ .

A determinação da orientação do descritor ocorre dentro de uma máscara (8x8) focada no ponto de interesse. Sendo obtido a resposta de wavelet de Haar para cada elemento nas direções  $xy$  denominadas como  $d_x$  e  $d_y$ . Para cada sub-região 2x2,  $d_x$ ,  $d_y$ ,  $|d_x|$  e  $|d_y|$  são acumuladas separadamente, gerando 16 conjuntos com as quatro características ( $\{\sum d_x, \sum d_y, \sum |d_x|, \sum |d_y|\}$ ), num total de 64 elementos, onde cada ponto é invariante a translação, luminosidade e projeções 3D e potenciais candidatos descritores de  $I$  (BAY et al. 2006; BAY et al. 2008; MARTINS, 2014). A Figura 2 ilustra pontos de interesse identificados pelo SURF.



**Figura 2.** Ilustração de pontos de interesse (papel hidrossensível) identificados pelo descritor SURF em imagem capturada a campo.

Para treinamento do descritor SURF para detecção automática de papel hidrossensível, o pacote `image.dlib` (WIJFFELS, 2020) foi utilizado para obtenção dos descritores SURF de papéis a partir de 60 imagens recortadas manualmente. O conjunto de descritores ‘treinados’ foi armazenado na forma de matriz numérica para servir como detector em novas imagens. As imagens utilizadas para construção do detector foram excluídas das imagens utilizadas para validação.

Para a localização do papel em novas imagens, aplicou-se o algoritmo de busca dos  $k$  vizinhos mais próximos (*k-nearest neighbors*) implementado no pacote FNN (BEYGELZIMER et al., 2019), baseando-se em análise de distância entre o descritor SURF da imagem sob análise e o descritor SURF treinado previamente. Em cada vetor SURF da imagem sob pesquisa, utilizou-se  $k = 1$ , procurando assim apenas pelo primeiro ponto mais próximo. O número de pontos selecionados variou entre 10 e 100, respeitando ainda um critério de razão de aspecto das dimensões do papel (76 x 26 mm). A partir das coordenadas  $xy$  (coluna, linha) dos pontos SURF selecionados, extraiu-se o retângulo suposto conter o papel.


### 3.3. Processamento das imagens

As imagens foram submetidas a quatro métodos de segmentação (Tabela 1), aplicados em imagens capturadas nos dois ambientes, campo e laboratório, para gerar a máscara binária de pixels de gotas (Figura 3).

**Tabela 1.** Métodos de segmentação de imagens obtidas em dois ambientes: campo (iluminação natural) e laboratório (iluminação artificial).

Id.	Espaço de cor	Método
1	HUE	210-260
2	ExB	Otsu
3	ExB	Thresh Adaptativo
4	RGB	Rede neural

HUE: Matiz; ExB: Excesso de Azul; RGB: intensidade (0-255) nos canais *Red-Green-Blue*.



**Figura 3.** (A) Imagem do papel em campo e recortado pelo descritor SURF, (B) máscara binária resultante de segmentação.

Pelo fato de o papel ser sensível à água, as regiões atingidas pela calda de pulverização tornam-se azuis. Essa mudança de cor ocorre devido à reação da água com o indicador azul bromofenol presente no papel hidrossensível (FOX et al., 2003; ZHU et al., 2011; CUNHA et al., 2013; NANSEN et al., 2015; FERGUSON et al., 2016a; MACHADO et al., 2018). Assim, foram aplicados os seguintes índices de cor na etapa de segmentação: *Hue* (Gonzalez & Woods, 2007) e *ExB* (Excesso de azul) adaptado do *ExG* de Woebbecke et al. (1995).

### 3.4. Índices de cor

*Hue*: As imagens são transformadas do sistema de cor RGB (*red, green, blue*) para o sistema HSI (*hue, saturation, intensity*), em que as cores são representadas unicamente pelo componente matiz (*hue*), podendo ser corrigida por saturação e brilho. A conversão consiste em aplicar as equações 2 e 3, como apresentadas por Gonzalez & Woods (2007).

$$\begin{aligned}
 H &= \begin{cases} \theta & \text{se } B < G \\ 360 - \theta & \text{se } B > G \end{cases} \\
 S &= 1 - \frac{\min(R, G, B)}{R + G + B} \\
 I &= \frac{R + G + B}{3}
 \end{aligned} \tag{2}$$

Em que  $\theta$  é uma variável angular intermediária e pode ser calculada usando a seguinte equação 3:

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{\frac{1}{2}}} \right\} \tag{3}$$

*ExB*: representa o excesso de azul em cada pixel, equação 4, adaptada do excesso de verde (*ExG*) de Woebbecke et al. (1995).

$$ExB = 2B - (G + R) \tag{4}$$

### 3.5. Métodos de segmentação


A determinação dos parâmetros de pulverização foi realizada após classificação dos pixels correspondentes às gotas. Para isso, os seguintes métodos foram aplicados: Otsu, *Threshold* adaptativo e Rede neural artificial.

*Otsu*: Os índices de cor foram submetidos ao método de Otsu (1979), que consiste em um algoritmo de limiarização (*threshold*) cuja função objetivo é maximizar a variância entre duas classes a partir de um histograma de frequências.

*Threshold* adaptativo: O *threshold* adaptativo é realizado por  $X > XM + \mu$ , em que  $X$  é o produto de convolução rápida,  $M$  uma máscara de vizinhança e  $\mu$  um parâmetro de deslocamento onde o limiar se ajusta aos parâmetros determinados (PAU et al., 2010).

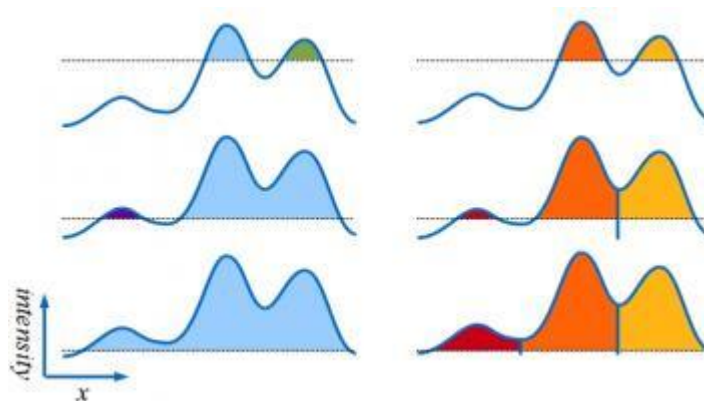
Rede neural artificial: As redes neurais podem ser utilizadas para construir modelos preditivos, de regressão ou de classificação, eficaz para lidar com processos complexos multidimensionais, envolvendo duas ou mais classes, separadas linear ou não linearmente. Diversas variações são encontradas na literatura e nos softwares, desde as mais simples como *perceptron* até as redes convolucionais. O funcionamento geral de uma rede é similar, guardadas as proporções de complexidade, ao do cérebro humano, em que neurônios transmitem informações através de sinapses (conexões). Foram treinadas redes do tipo *feed-forward* de uma a três camadas ocultas, utilizando como *input* cerca de

5 mil amostras de pixels nos canais RGB manualmente identificados como sendo das classes “gotas”, “papel” e “fundo” (Figura 4). Utilizou-se 70% dos pixels para determinar os pesos conexões sinápticas entre os neurônios da rede. O percentual de classificação correta (acurácia) foi utilizado como critério de validação cruzada com 30% dos dados.



**Figura 4.** Ilustração de rede neural com duas camadas ocultas.

Após segmentação da região de interesse (gotas/papel), o algoritmo *watershad* foi aplicado para detecção de gotas sobrepostas (Figura 5). Em suma, o algoritmo identifica e separa objetos que se destacam do fundo (pixels regionais de valor zero). Ele inverte a imagem e usa “água” para preencher os valores resultantes (pixels com alta intensidade na imagem de origem) até que outro objeto ou fundo seja encontrado. Os vales mais profundos são indexados primeiro, começando em 1 (PAU et al., 2010).



**Figura 5.** Visão geral esquemática do algoritmo de inundação para o método de watershed. Fonte: <https://svi.nl/watershad>

O algoritmo Watershad, pode ser entendida imaginando um relevo como mostra a figura x, que contenha bacias e montanhas que ao ser inundadas elas formam linhas divisórias, esta “inundação” ocorre por fator do gradiente (alteração do valor do pixel por unidade de espaço (GEORGE B. THOMAS, 2002)) a imagem se torna numa espécie de relevo, em que as regiões baixas são representadas por menor gradiente, e as mais altas são representadas por maior gradiente.

### 3.6. Estimação dos parâmetros de pulverização

Após a segmentação, o número de pixels de cada objeto disjunto (entenda-se como gota) foi computado na imagem binarizada. A partir disto, e considerando as dimensões do papel (76 x 26 mm), foram estimados os parâmetros de pulverização contidos na Tabela 2.

**Tabela 2.** Parâmetros de pulverização.

1	Quantidade de Gotas
2	Área Coberta (%)
3	Densidade (gotas/cm <sup>2</sup> )
4	Diâmetro Médio (µm)
5	Volume aplicado
6	Volume de calda (L ha <sup>-1</sup> )
7	DMN (µm), Diâmetro Mediano Numérico
8	DMV (µm), Diâmetro Mediano Volumétrico
9	D0.1 (µm), DMV para 10% volume depositado
10	D0.9 (µm), DMV para 90% volume depositado
11	Amplitude Relativa
12	Maior Gota (µm)
13	Menor Gota (µm)
14	Classificação de gotas por produto e alvo biológico
15	Coefficiente de Variação da área (%)
16	Coefficiente de Variação do diâmetro (%)
17	Potencial de deriva

*Quantidade de gotas*

A quantidade de gotas é a contagem de gotas que atingiram o alvo selecionado, também chamado de número total de gotas (RAMOS et al., 2010).

*Área Coberta (%)*

A área de cobertura (%) (Equação 6) é dependente do volume de calda da taxa de recuperação da calda nas folhas, do fator de espalhamento de gotas, da área foliar da vegetação e do diâmetro das gotas, sendo este um dos princípios básicos da tecnologia de aplicação, não existindo uma área de cobertura que seja solução única para todas as situações, demandado ajustes para cada condição de aplicação (RODRIGUES et al., 2011).

A cobertura dos alvos de uma aplicação é definida pela fórmula 6:

$$C = \frac{G}{N} \quad (6)$$

Sendo  $G$  a quantidade de pixels classificados como ‘gota’, e  $N$  o total de pixels na imagem.

#### *Densidade*

A densidade representa o número de gotas em determinada unidade de área, em geral dado em gotas/cm<sup>2</sup>. Essa variável é intimamente relacionada com a quantidade de defensivo fitossanitário que é depositado sobre o alvo desejado (RAMOS et al., 2010).

#### *Diâmetro médio*

O diâmetro médio é obtido pela média aritmética dos diâmetros das gotas (RAMOS et al., 2010).

#### *Volume depositado*

O volume depositado é a quantidade de produto fitossanitário que atinge o alvo, se referindo a parcela do volume de calda pulverizado que eficientemente realizou a cobertura do alvo (RAMOS et al., 2010).

O volume depositado foi calculado por  $V = \sum_{i=1}^n V_i$ , sendo  $V_i$  o volume de gota, dado pela fórmula 7:

$$V_i = \frac{\pi(\emptyset/1000)^3}{6} \quad (7)$$

Sendo  $\emptyset$  o diâmetro de gota ( $\mu\text{m}$ ),  $\pi$  uma constante matemática cujo valor se aproxima a 3,14159.

#### *Volume de calda*

O volume de pulverização não se trata de algo fixo, o volume utilizado varia conforme a necessidade situacional para uma aplicação eficaz. Fatores como alvo desejado, tipo de ponta utilizado, condições climáticas, arquitetura da planta, tipo de produto a ser aplicado velocidade de aplicação e nível de tecnificação afetam o volume de pulverização (RAMOS et al, 2010).



*Diâmetro mediano numérico*

O diâmetro mediano numérico é o valor de diâmetro em que ocorre a divisão do número de gotas em duas partes iguais em quantidade de gotas (GARCIA et al., 2004).

*Diâmetro mediano volumétrico*

O diâmetro mediano volumétrico é o diâmetro em que ocorre a divisão do volume depositado em duas partes iguais, sendo também chamado de D<sub>0,5</sub>. Na parte inferior há gotas de menor tamanho (GARCIA et al., 2004).

Deste parâmetro são derivados dois outros muito usados na tecnologia de aplicação, sendo eles D<sub>0,1</sub> e D<sub>0,9</sub>. O primeiro determina o diâmetro de gota que delimita 10% do volume depositado; o segundo delimita 90% (GARCIA et al., 2004).

*Amplitude relativa*

A amplitude relativa (Equação 8) demonstra o padrão de uniformidade do espectro de gotas, representando a variação do tamanho de gotas. Quanto maior for o valor da amplitude relativa, maior é a faixa de tamanho de gotas aplicadas e menor a uniformidade (RODRIGUES et al., 2011).

A amplitude relativa é obtida através da equação:

$$AR = \frac{D_{v0,9} - D_{v0,1}}{D_{v0,5}} \quad (8)$$

Sendo AR - amplitude relativa; D<sub>v0,9</sub> - diâmetro volumétrico de 90%; D<sub>v0,1</sub> - diâmetro volumétrico de 10% e D<sub>v0,5</sub> - diâmetro volumétrico de 50%.

*Classes de tamanho*

A ponta de pulverização não fornece um único tamanho de gota. A menor gota é a que possui o menor diâmetro (µm) e a maior gota é aquela com o maior diâmetro (µm) (RAMOS et al., 2010). Pode-se ainda recorrer a uma classificação da faixa de diâmetro de gotas em finas (< 105 µm), médias (106-340 µm) e grossas (> 341 µm) (ASAE, 2009).

*Classificação de gotas por produto e alvo biológico*

A classificação do tamanho de gota é determinada pelo tipo do produto e pelo alvo a ser atingido, sendo recomendado utilizar gotas muito finas (61-105 µm) e finas (106-235 µm) para fungicidas de contato, finas (106-235 µm) e médias (236-340 µm) para fungicidas sistêmicos e inseticidas de contato, médias (236-340 µm) e grossas (341-403 µm) para inseticidas sistêmicos, finas (106-235 µm), médias (236-340 µm) e grossas (341-403 µm) para herbicidas pós emergentes de contato e médias (236-340 µm), grossas

(341-403  $\mu\text{m}$ ) e muito grossas (404-502  $\mu\text{m}$ ) para herbicidas pré emergentes e pós emergentes sistêmicos (COSTA, 2019; ASAE, 2009).

#### *Coefficiente de variação*

A uniformidade de aplicação é um fator extremamente importante para avaliar a qualidade da pulverização e para garantir a deposição da dose recomendada no alvo selecionado. A uniformidade de aplicação está relacionada com a amplitude relativa. Quanto maior a amplitude relativa, menor a uniformidade a aplicação. Quanto mais próximo de zero for a amplitude relativa, mais uniforme é a deposição (CARVALHO et al., 2017). A uniformidade de aplicação pode também ser avaliada através do coeficiente de variação (CV%) das áreas ou dos diâmetros das gotas. O CV% é calculado pela razão entre o desvio padrão e a média.

#### *Potencial de deriva*

O potencial de deriva se refere a possibilidade da gota se desviar ou não atingir o alvo desejado, podendo ocorrer por ação do vento, escorrimento, volatilização e tamanho de gota (RAMOS et al., 2010). O método de Rautmann et al. (2001), um aprimoramento do modelo alemão (GANZELMEIER et al., 1995), que quantifica vestígios de produtos fitossanitários no solo que representa 0,01% da taxa de pulverização, estes vestígios possibilitam analisar a área de deriva em até 100 m da área pulverizada, possibilitando a análise da deriva pela equação 9:

$$drift = 100 - 2,7705 \text{ distancia}^{-0.9787} \quad (9)$$


Onde *drift* representa o sedimento do solo em porcentagem da distância *x* em metros, 2,7705 e -0.9787 são parâmetros calculados a partir dos valores medidos para culturas anuais (RAUTMANN et al., 2001).

O tamanho de gota representa um fator importante no potencial de deriva onde gotas finas apresentam alto risco de deriva (GODINHO JUNIOR et al., 2017a).

### **3.7. Validação**

Foi realizada uma validação em relação a detecção de gotas. Utilizando-se de 10 papéis hidrossensíveis, depositou-se entre 10 e 20 gotículas em cada um manualmente, com o auxílio de uma haste de metal (Figura 6) para dar forma as gotas, esse método de

validação foi utilizado devido a possibilitar a determinação exata dos parâmetros para posterior comparação. Após a contagem manual, as imagens foram analisadas pelo pacote *hydropaper*, e pelos softwares *DropScope* e *Gotas*. Os resultados obtidos foram submetidos a uma análise descritiva.



**Figura 6.** Deposição manual de gotas no papel hidrossensível, para validação.

### 3.8. Computação

Os códigos computacionais para desenvolvimento do pacote foram escritos em linguagem R ([www.r-project.org](http://www.r-project.org)), livre, tendo como suporte para o processamento de imagens as implementações do pacote EBImage (PAU et al., 2010). Para treinamento de redes neurais, o pacote caret (KUNH et al., 2021) foi utilizado.

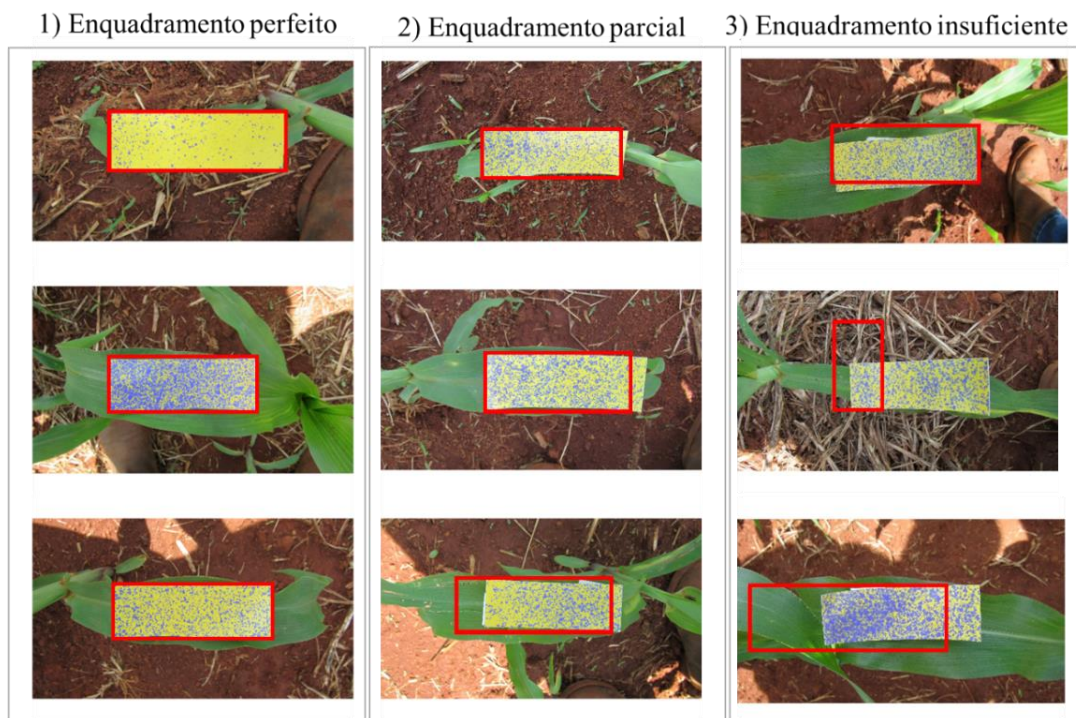
Um repositório na plataforma GitHub foi criado para hospedar o pacote, no endereço: <https://arsilva87.github.io/hydropaper>. A versão 0.1 (*pre-release*) já se encontra disponível para instalação.

Os dados extraídos de 10 imagens foram apresentados de forma descritiva no decorrer do texto e posteriormente foi calculada a correlação de Pearson desses dados com os obtidos com software disponível no mercado, aqui tomado como referência.

## 4. RESULTADOS


### 4.1. Detector de papel hidrossensível

Para ser identificado pelo descritor SURF, o papel deve estar sempre posicionado no sentido vertical ou horizontal da imagem, o SURF se mostrou eficiente na localização da área de interesse na imagem. A figura 7 mostra exemplos de 3 tipos de recorte do papel: enquadramento perfeito, se caracteriza quando o papel se encaixa 100% dentro da caixa de foco produzida pelo descritor SURF, o que possibilita um processamento da imagem que recorte somente o papel; enquadramento parcial, que se caracteriza quando o papel não se encaixa 100% dentro da caixa produzida pelo descritor, ocorre quando há ruídos, como partículas de solo ou planta na imagem a ser processada, porém a parte de maior interesse na imagem ainda é o papel; enquadramento insuficiente, se caracteriza quando a maior parte do papel fica fora da caixa foco produzida pelo descritor SURF, onde perdemos parte significativa do papel a ser analisado, possuindo em sua maior parte, ruídos (solo e planta) . Podemos observar alguns exemplos destas classificações, nos testes da caixa de foco utilizando o método Surf, que consistiu em utilizar 108 imagens, 75% com enquadramento perfeito, 21% com enquadramento parcial e 4% de enquadramento insuficiente.



**Figura 7.** Performance do descritor SURF (*Speeded Up Robust Features*) para localização do papel hidrossensível em imagens tiradas em condições de campo (iluminação natural).

O método descritor SURF é altamente responsivo ao ângulo de captura da imagem. Portanto deve-se enquadrar horizontal ou verticalmente o papel na tela do aparelho de captura (Figura 8).



**Figura 8.** (À esquerda) Enquadramento adequado do papel na tela do aparelho de captura em campo; (à direita) Enquadramento incorreto do papel na tela do aparelho de captura em campo.

Espera-se que o papel ocupe a maior parte da imagem. Além disso, é muito importante que o papel esteja alinhado o mais horizontalmente (ou verticalmente) possível, para ser detectado corretamente. Deve-se ter em mente que um recorte

retangular será extraído – *o procedimento deve ser análogo ao da leitura de um código de barras com uma câmera.*

É altamente recomendável capturar pelo menos três imagens de cada papel. Embora isso implique em maior demanda computacional, é um esforço que compensa em termos de precisão das estimativas dos parâmetros de pulverização.

Outro fator importante é a resolução ótica. Recomenda-se que as imagens tenham pelo menos 180 PPI (pixels por polegada). Por outro lado, imagens de resolução muito alta podem exigir mais poder de processamento e tempo, não necessariamente resultando em maior precisão.

Os formatos de imagem RGB mais comuns são aceitos, como .jpg, .png, .tif.

Finalmente, deve-se tentar obter o mínimo possível de variação de sombra/luz do sol sobre o papel. Não há problema se houver esse tipo de variação no fundo, mas não no papel. Em geral não importa que imagens diferentes sejam tiradas em condições de iluminação diferentes, desde que sejam de boa qualidade conforme os critérios acima. Portanto, desde que os critérios sejam seguidos o SURF se mostrou um descritor eficaz na determinação da área de interesse (papéis hidrossensíveis).

#### **4.2. Imagens-teste de campo**

Ao analisar os parâmetros principais da pulverização: número de gotas (Tabela 3), densidade (Tabela 4), DMV (Tabela 5), maior gota (Tabela 6), menor gota (Tabela 7) e amplitude relativa (Tabela 8) de dez imagens é possível notar similaridades entre os métodos de processamento utilizados, utilizando software já implementados e renomados. A média do número de gotas obtida com o método da rede neural ( $\bar{x} = 2200,42$  gotas) foi a que mais se aproximou da média obtida com o DropScope® ( $\bar{x} = 2386,08$  gotas). A maior diferença de foi obtida com a utilização do método ExB+Thresh ( $\bar{x} = 753.33$  gotas) (Tabela 3).

**Tabela 3.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável número de gotas.

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	393	572	358	1824	1710	1004
2	673	635	635	1758	1282	1217
3	1074	1061	998	2551	2529	2270
4	693	742	455	1537	1728	1360
5	1145	1189	991	3031	3634	3515
6	1304	1309	1021	2414	2538	2637
7	711	670	914	2168	7065	3683
8	1177	1151	892	2565	2486	2665
9	1260	1073	1033	3057	3133	4446
10	1023	1168	818	2295	2794	2591
11	306	628	250	1533	1784	1134
12	910	1039	675	1672	2725	2111

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

A média de densidade de gotas obtida com o método da rede neural ( $\bar{x} = 111,42$  gotas/cm<sup>2</sup>) também foi a que mais se aproximou do valor obtido com o DropScope® ( $\bar{x} = 150,00$  gotas/cm<sup>2</sup>) (Tabela 4).

**Tabela 4.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável densidade de gotas (gotas/cm<sup>2</sup>)

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	20	29	18	92	5.14	63.11
2	34	32	32	89	3.35	76.5
3	54	54	51	129	7.45	142.7
4	35	38	23	78	4.82	85.49
5	58	60	50	153	9.95	220.96
6	66	66	52	122	6.96	165.77
7	36	34	46	110	17.85	231.52
8	60	58	45	130	6.81	167.53
9	64	54	52	155	9.32	279.49
10	52	59	41	116	7.8	162.88
11	15	32	13	78	4.64	71.29
12	46	53	34	85	7.49	132.7

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

O método que mais se aproximou do DropScope® na estimativa do Diâmetro Médio Volumétrico (DMV) de gotas foi ExB+Thresh ( $\bar{x} = 413,55 \mu\text{m}$ ) (Tabela 5).

**Tabela 5.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável diâmetro mediando volumétrico (DMV) ( $\mu\text{m}$ ).

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	463.66	521.76	431.69	407.32	1110.21	323.41
2	489.85	527.4	352.53	407.73	1289.56	278.39
3	531.6	661.01	438.2	423.06	1308.85	298.49
4	449.56	528.68	306.41	335.44	1039.16	222.23
5	603.54	754.42	466.68	495.09	1409.31	308.49
6	399.54	526.76	338.38	352.89	1014.19	237.69
7	1168.65	1270.45	444.88	769.14	967.27	535.5
8	587.86	686.58	482.53	468.79	1334.97	318.45
9	678.01	824.01	388.22	498.68	1606.23	308.49
10	526.19	656.2	438.83	432.19	1242.52	298.49
11	563.47	664.32	489.6	492.03	1400.36	377.54
12	486.99	581.57	384.68	403.94	1197.56	348.13

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Todos os métodos foram eficientes na determinação da menor gota. O Gotas não fornece esta estimativa. Os métodos Rede Neural ( $\bar{x} = 33,75 \mu\text{m}$ ), Hue ( $\bar{x} = 33,75 \mu\text{m}$ ) e ExB+Otsu ( $\bar{x} = 33,75 \mu\text{m}$ ) apresentaram a menor diferença de valor entre os métodos analisados em relação ao DropScope® ( $\bar{x} = 24,82 \mu\text{m}$ ), a maior diferença de valor ocorreu no método ExB+Thresh ( $\bar{x} = 34,66 \mu\text{m}$ ) (Tabela 6).



**Tabela 6.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável menor gota ( $\mu\text{m}$ ).

Img.	Métodos					Gotas	DropScope®
	Hue	ExB+Otsu	ExB+Thresh	Rede neural			
1	30.29	30.29	30.29	30.29	-	24.82	
2	29.07	29.07	29.07	29.07	-	24.82	
3	33.74	33.74	33.74	33.74	-	24.82	
4	33.55	33.55	33.55	33.55	-	24.82	
5	34.53	34.53	34.53	34.53	-	24.82	
6	36.23	36.23	36.23	36.23	-	24.82	
7	33.87	33.87	33.87	33.87	-	24.82	
8	35.82	35.82	35.82	35.82	-	24.82	
9	34.41	34.41	34.41	34.41	-	24.82	
10	36.03	36.03	36.03	36.03	-	24.82	
11	35.31	35.31	46.19	35.31	-	24.82	
12	32.21	32.21	32.21	32.21	-	24.82	

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Na determinação da maior gota, o método que numericamente apresentou menor diferença de valores em relação ao DropScope® ( $\bar{x} = 651,16 \mu\text{m}$ ) foi o ExB+Thresh ( $\bar{x} = 1113,78 \mu\text{m}$ ), a maior diferença de valor ocorreu no método ExB+Otsu ( $\bar{x} = 4235,54 \mu\text{m}$ ) O Gotas® não fornece esse parâmetro (Tabela 7). Em todos os métodos propostos, a dificuldade apontada por HOFFMAN; HEWITT (2005) quanto a limitação técnica ao uso de software de análise de gotas em papéis sensíveis, que se deve a dificuldade de leitura e análise de gotas muito pequenas, abaixo de  $50 \mu\text{m}$ , foi solucionada, uma vez que em que todos os papéis analisados o diâmetro da menor gota ficou inferior a  $50 \mu\text{m}$ .

**Tabela 7.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável maior gota ( $\mu\text{m}$ ).

Img.	Métodos				Gotas	DropScope®
	Hue	ExB+Otsu	ExB+Thresh	Rede neural		
1	1220.12	1351.09	1065.28	1973.91	-	596.34
2	2155.34	2293.96	1424.23	1587.79	-	647.33
3	1491.47	3804.08	1106.53	2573.04	-	540.2
4	1458.72	7917.32	818.58	937.8	-	502.45
5	1797.29	13269.9	1257.16	1365.68	-	577.69
6	1452.99	1901.38	1011.98	1339.25	-	478.71
7	5042.23	6831.26	1153.59	2135.41	-	1187.92
8	1772.04	3163.93	1168.81	1280.23	-	610.29
9	4680.88	2898.85	1055.44	2530.82	-	697.92
10	1709.3	2017.66	1016.8	1897.98	-	577.69
11	1327.2	1697.45	1089.68	1825.75	-	554.29
12	4887.18	3679.61	1197.38	1920.73	-	843.15

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

O método que mais se aproximou do DropScope® ( $\bar{x} = 0,99$ ) na estimativa da Amplitude Relativa (AR) foi o método ExB+Thresh ( $\bar{x} = 1$ ). A maior diferença de valor ocorreu no método ExB+Otsu ( $\bar{x} = 1,34$ ). O método Gotas® não fornece esse parâmetro (Tabela 8).

**Tabela 8.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável amplitude relativa.

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	0.98	1.09	0.84	1.09	-	0.86
2	1.49	1.52	0.98	1.09	-	1.18
3	1.09	1.24	1.02	1.04	-	0.87
4	1.3	1.44	1.2	1.15	-	0.92
5	1.12	1.26	0.92	1.02	-	0.86
6	1.31	1.37	1.18	1.08	-	0.91
7	1.69	1.6	0.95	1.08	-	1.31
8	1.18	1.45	0.98	1.12	-	0.99
9	1.31	1.41	0.98	1	-	0.98
10	1.02	1.14	0.98	1.01	-	0.91
11	0.8	1.11	0.76	1.07	-	0.54
12	1.28	1.55	1.21	1.16	-	1.6

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Ao analisar a correlação de Pearson quanto aos métodos de processamento em imagens capturadas no campo em relação as referências (DropScope® e Gotas®), nota-se que para a referência DropScope® o método Hue apresentou forte correlação para todos os parâmetros da pulverização. O método de rede neural apresentou forte correlação quanto aos parâmetros número de gotas, densidade e DMV. O Exb + Otsu quanto a DMV e AR. E o ExB + Thresh quanto ao número de gotas e densidade. O método Hue apresentou o maior número de correlações fortes enquanto o método de rede neural apresentou as correlações mais fortes. Quanto a referência Gotas®, nenhum método apresentou correlação forte, chegando a apresentar uma fraca correlação negativa para o parâmetro DMV (Tabela 9).

**Tabela 9.** Coeficiente de correlação de Pearson do método de segmentação com os softwares de referência para imagens capturadas em campo

Método	Referência	N gotas	Densidade	DMV	Menor gota	Maior gota	AR
Hue	Gotas	0.181	0.243	-0.107	-	-	-
Hue	DropScope®	0.714	0.716	<b>0.883</b>	-	<b>0.839</b>	<b>0.702</b>
Exb + Otsu	Gotas	0.066	0.120	-0.039	-	-	-
Exb + Otsu	DropScope®	0.566	0.560	<b>0.847</b>	-	0.145	<b>0.790</b>
ExB + Thresh	Gotas	0.492	0.538	0.377	-	-	-
ExB + Thresh	DropScope®	<b>0.834</b>	<b>0.829</b>	0.543	-	0.300	0.547
Rede neural	Gotas	0.343	0.418	-0.021	-	-	-
Rede neural	DropScope®	<b>0.835</b>	<b>0.838</b>	<b>0.925</b>	-	0.368	0.465

### 4.3. Imagens-teste de laboratório

Quando avaliado em laboratório, o método Gotas® ( $\bar{x} = 2784,00$  gotas) apresentou a menor diferença de valor entre os métodos analisados em relação ao DropScope® ( $\bar{x} = 2386,08$  gotas). A maior diferença de valor ocorreu no método Rede Neural ( $\bar{x} = 7276,25$  gotas) (Tabela 10).

**Tabela 10.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável número de gotas.

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	288	433	251	2870	1710	1004
2	538	650	501	3512	1282	1217
3	969	976	858	6561	2529	2270
4	574	692	492	20159	1728	1360
5	1189	1193	906	6478	3634	3515
6	1264	1375	969	10272	2538	2637
7	538	542	465	3367	7065	3683
8	1179	1247	868	7676	2486	2665
9	1136	1047	896	4676	3133	4446
10	969	1195	798	4906	2794	2591
11	307	520	271	6211	1784	1134
12	699	918	586	10627	2725	2111

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Na estimativa da densidade de gotas houve similaridades entre o método Rede neural ( $\bar{x} = 368,16$  gotas/cm<sup>2</sup>), que apresentou a menor diferença de valor entre os métodos analisados em relação ao DropScope® ( $\bar{x} = 149,99$  gotas/cm<sup>2</sup>). A maior diferença de valor ocorreu no método Gotas® ( $\bar{x} = 7,63$  gotas/cm<sup>2</sup>) (Tabela 11).

**Tabela 11.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável densidade (gotas/cm<sup>2</sup>).

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	15	22	13	145	5.14	63.11
2	27	33	25	178	3.35	76.5
3	49	49	43	332	7.45	142.7
4	29	35	25	1020	4.82	85.49
5	60	60	46	328	9.95	220.96
6	64	70	49	520	6.96	165.77
7	27	27	24	170	17.85	231.52
8	60	63	44	388	6.81	167.53
9	57	53	45	237	9.32	279.49
10	49	60	40	248	7.8	162.88
11	16	26	14	314	4.64	71.29
12	35	46	30	538	7.49	132.7

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Para a estimativa do parâmetro DMV foi possível notar similaridades entre o método ExB+Thresh ( $\bar{x} = 416,87$   $\mu\text{m}$ ) que apresentou a menor diferença de valor entre os métodos analisados em relação ao DropScope® ( $\bar{x} = 321,28$   $\mu\text{m}$ ). A maior diferença de valor ocorreu no método Gotas® ( $\bar{x} = 1243,35$   $\mu\text{m}$ ) (Tabela 12).

**Tabela 12.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável diâmetro mediano volumétrico (DMV) ( $\mu\text{m}$ ).

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	491.07	539.34	435.78	384.32	1110.21	323.41
2	548.05	618.71	348.87	454.73	1289.56	278.39
3	596.26	688.14	446.27	529.42	1308.85	298.49
4	446.25	520.01	302.55	279.75	1039.16	222.23
5	656.23	755.33	414.87	525.69	1409.31	308.49
6	427.59	512.41	346.82	413.7	1014.19	237.69
7	1411.25	1437.47	450.72	836.25	967.27	535.5
8	608.65	662.61	466.34	443.72	1334.97	318.45
9	869.87	994.88	403.86	596.03	1606.23	308.49
10	562.65	618.85	440.77	470.68	1242.52	298.49
11	646.96	673.61	547.03	314.8	1400.36	377.54
12	528.54	565.64	398.67	369.1	1197.56	348.13

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Na estimativa da menor gota houve similaridades entre os métodos de segmentação, visto que foram capazes de identificar a menor gota. Os métodos Rede Neural ( $\bar{x} = 32,99 \mu\text{m}$ ), Hue ( $\bar{x} = 32,99 \mu\text{m}$ ) e ExB+Otsu ( $\bar{x} = 32,99 \mu\text{m}$ ) apresentaram a menor diferença de valor entre os métodos analisados em relação ao DropScope® ( $\bar{x} = 24,82 \mu\text{m}$ ), a maior diferença de valor ocorreu no método ExB+Thresh ( $\bar{x} = 33,87 \mu\text{m}$ ). O método Gotas® não fornece esse parâmetro (Tabela 13).

**Tabela 13.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável menor gota ( $\mu\text{m}$ ).

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	34.41	34.41	45	34.41	-	24.82
2	32.06	32.06	32.06	32.06	-	24.82
3	34.04	34.04	34.04	34.04	-	24.82
4	33.13	33.13	33.13	33.13	-	24.82
5	32.82	32.82	32.82	32.82	-	24.82
6	32.86	32.86	32.86	32.86	-	24.82
7	31.53	31.53	31.53	31.53	-	24.82
8	32.83	32.83	32.83	32.83	-	24.82
9	34.2	34.2	34.2	34.2	-	24.82
10	33.13	33.13	33.13	33.13	-	24.82
11	32	32	32	32	-	24.82
12	32.88	32.88	32.88	32.88	-	24.82

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Quanto ao parâmetro maior gota, o método que numericamente apresentou menor diferença de valores em relação ao DropScope® ( $\bar{x} = 651,16 \mu\text{m}$ ) foi o ExB+Thresh ( $\bar{x} = 1059,06 \mu\text{m}$ ). A maior diferença de valor ocorreu no método ExB+Otsu ( $\bar{x} = 2446,29 \mu\text{m}$ ). O método Gotas® não fornece esse parâmetro (Tabela 14).

**Tabela 14.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável maior gota ( $\mu\text{m}$ ).

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	1283.25	1329.21	1079.14	941.18	-	596.34
2	4282.49	4448.44	986.71	1156.08	-	647.33
3	1681.96	1936.01	1108.97	1255.75	-	540.2
4	1262.15	1950.17	854.68	895.17	-	502.45
5	1863.08	2264.09	1020.65	1258.82	-	577.69
6	1501.14	1881.16	987.81	1025	-	478.71
7	4351.72	5172.65	1087.28	2176.14	-	1187.92
8	2011.2	2195.31	1189.47	1283.64	-	610.29
9	2757.75	3163.9	985.3	1462.21	-	697.92
10	1359.62	1649.73	1049.91	1215.05	-	577.69
11	1537.11	1607.51	1218.22	1095.09	-	554.29
12	1609.66	1757.34	1140.69	1114.94	-	843.15

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Foram observadas similaridades para a estimativa da Amplitude Relativa (AR) entre o método ExB+Thresh ( $\bar{x} = 1,01$ ), e o DropScope® ( $\bar{x} = 0,99$ ). A maior diferença de valor ocorreu no método ExB+Otsu ( $\bar{x} = 1,33$ ), o Gotas® não fornece esse parâmetro (Tabela 15).



**Tabela 15.** Validação cruzada para os métodos de segmentação versus os softwares Gotas Embrapa e DropScope® na variável amplitude relativa.

Img.	Métodos					
	Hue	ExB+Otsu	ExB+Thresh	Rede neural	Gotas	DropScope®
1	1	0.96	0.96	1.24	-	0.86
2	1.82	2.17	1.05	1	-	1.18
3	1.1	1.18	0.97	1.05	-	0.87
4	1.3	1.39	1.14	1.25	-	0.92
5	1.13	1.24	0.94	1.06	-	0.86
6	1.34	1.37	1.17	1	-	0.91
7	1.38	1.77	0.94	1.01	-	1.31
8	1.21	1.34	1	1.29	-	0.99
9	1.28	1.41	0.94	1.08	-	0.98
10	0.94	1.06	0.97	1.12	-	0.91
11	0.7	0.78	0.74	1.77	-	0.54
12	1.35	1.4	1.32	1.31	-	1.6

Hue; Matiz de cores HSV. ExB; Índice de Excesso de Azul.

Ao analisar a correlação de Pearson quanto aos métodos de processamento em imagens capturadas no laboratório em relação as referências (DropScope® e Gotas®), nota-se que para a referência DropScope® os métodos rede neural e Exb + Otsu apresentaram forte correlação ( $> 0,7$ ) para o parâmetro maior gota, sendo que a correlação mais forte ocorreu no método rede neural. O método rede neural apresentou uma fraca correlação para o parâmetro AR. Em relação à referência Gotas®, nenhum método apresentou correlação forte (Tabela 16).


**Tabela 16.** Correlação método vs referência para imagens capturadas em laboratório.

Método	Referência	N gotas	Densidade	DMV*	Menor gota	Maior gota	AR*
Hue	Gotas	0.126	0.177	-0.041	-	-	-
Hue	DropScope®	<b>0.679</b>	<b>0.672</b>	0.275	-	0.673	0.665
Exb + Otsu	Gotas	0.001	0.041	0.014	-	-	-
Exb + Otsu	DropScope®	0.527	0.523	0.255	-	0.703	0.641
ExB + Thresh	Gotas	0.122	0.191	0.354	-	-	-
ExB + Thresh	DropScope®	<b>0.667</b>	<b>0.673</b>	0.587	-	0.215	<b>0.694</b>
Rede neural	Gotas	-0.084	-0.198	-0.006	-	-	-
Rede neural	DropScope®	0.309	0.081	<b>0.678</b>	-	<b>0.846</b>	-0.372

\*DMV - diâmetro mediano volumétrico ( $\mu\text{m}$ ); AR - amplitude relativa.

As diferenças entre as correlações das imagens testem de campo e laboratório ocorreram devido a mudança de tonalidade das gotas após secarem no papel hidrossensível, visto que desde o início do processo de retirada do papel do campo, devido armazenamento e transporte até o laboratório foi necessário aproximadamente 2:30 horas. Este tempo pode ser considerado rápido para todo o processo requerido, porém suficiente para a secagem e mudança da tonalidade das gotículas depositadas sobre o papel hidrossensível. O uso do papel em condições de alta umidade relativa do ar pode ser comprometida por contaminação das amostras, que mudam a sua cor de amarela (Figura 9B) para azul (Figura 9C) devido o contato com a água da atmosfera (TURNER; HUNTINGTON, 1970), o que afeta bruscamente a precisão dos modelos propostos para a análise dos parâmetros de pulverização. Isso evidencia a importância da capacidade de analisar de a imagem com captura direta no campo, com objetivo de evitar queda na acurácia dos resultados (Figura 9).

#### 4.4. Validação



**Figura 9.** A) Imagem capturada no campo, B) Recorte do papel pelo descritor SURF da imagem capturada no campo, C) Imagem capturado no laboratório.


Ao observar os índices obtidos nas dez imagens utilizadas na validação cruzada os três softwares (hydropaper, DropScope® e Gotas) em relação com a referência (Real), nota-se que o *hydropaper* apresentou o maior número de resultados próximos ao real (menor índice de diferença real em seis imagens), seguido pelo DropScope® (menor índice de diferença real em três imagens) e por último o Gotas (menor índice de diferença real em uma imagem). Hydropaper também apresentou maior exatidão, sendo que em cinco imagens o hydropaper encontrou o número real de gotas. DropScope® encontrou o número exato de gotas apenas em uma imagem (Tabela 17).

**Tabela 17.** Validação cruzada entre o hydropaper e as referências DropScope®e Gotas.

Img.	Hydropaper		DropScope®		Gotas		Real
	Estimado	Dif. Real	Estimado	Dif. Real	Estimado	Dif. Real	
1	23	10	35	22	39	26	13
2	12	0	14	2	23	11	12
3	30	8	25	3	81	59	22
4	25	7	17	-1	30	12	18
5	29	12	17	0	24	7	17
6	20	0	18	-2	24	4	20
7	21	0	28	7	46	25	21
8	19	0	24	5	47	28	19
9	23	8	23	8	20	5	15
10	15	0	18	3	17	2	15

Dif. Real: Diferença entre o estimado e o real.

As imagens utilizadas para a validação foram coletas em campo (Figura 10A). hydropaper demonstrou ser capaz de identificar o papel hidrossensível de modo preciso (Figura 10B), não apresentando problemas quanto a luminosidade, também sendo capaz de detectar apropriadamente o papel (Figura 10C).


**Figura 10.** Processamento do papel hidrossensível com o hydropaper durante a validação.

A) Papel hidrossensível ao campo, B) Detecção do papel hidrossensível, C) Recorte do papel hidrossensível, D) Identificação das gotas com o hydropaper.

#### 4.5. Características do pacote

O pacote *hydropaper* foi desenvolvido para detectar imagens no papel sensível à água a partir de imagens de campo e fazer análises de desempenho de pulverização, possibilitando ao usuário praticidade e veracidade nos resultados.

Vistos os resultados de testes, principalmente com imagens de campo, mas também de laboratório, a versão atual do *hydropaper* foi implementada como método de rede neural. Durante o treinamento da rede, o gradiente de acurácia atingiu níveis superiores a 96%, com base em valores de intensidade nos canais *red* (R), *green* (G) e *blue* (B) para identificação das regiões de importância: fundo, gotas e papel (Figura 11).



**Figura 11.** Gradiente de acurácia (a esquerda) durante o treinamento de parâmetros (*hidden units*, *decay*) da rede neural obtida (3-18-3, a direita).

Há perspectiva de implementação de outro método, como o ExB+Threshold adaptativo, que apresentou também desempenho satisfatório com imagens de laboratório, de forma que o usuário possa selecionar o método.

A seguir são apresentadas as principais funcionalidades do pacote.

##### *detectPaper*

A função *detectPaper* detecta o papel hidrosensível nas imagens RGB usando um descritor pré-treinado SURF (*Speed Up Robust Features*). Comando de execução:

```
> detectPaper(x,
              paper_dim = c(76, 26),
              display.it = TRUE)
```

Onde:  $x$  pode ser ou um objeto da classe “Image”, lido com o pacote *EBImage*, ou um caractere que indica o caminho para o arquivo da imagem (.jpg, .jpeg, .png, .tif) a ser analisada; *paper\_dim* representa o vetor numérico das dimensões (comprimento e largura – mm) do papel hidrosensível; *display.it* determina que se a imagem com a caixa delimitadora deve ser exibida.

### *clipPaper*

A função *clipPaper* possibilita o corte do papel hidrosensível através de três cliques para análise posterior. Comando de execução:

```
> clipPaper(x)
```

Onde:  $x$  pode ser ou um objeto da classe “Image”, lido com o pacote *EBImage*, ou um caractere que indica o caminho para o arquivo da imagem (.jpg, .jpeg, .png, .tif) a ser analisada.

### *analyzePaper*

A função *analyzePaper* avalia a qualidade do spray analisando uma imagem RGB do papel hidrosensível. Comando de execução:

```
> analyzePaper(x,
               paper_dim = c(76, 26),
               distance = 0.7,
               display.it = TRUE)
```

Onde:  $x$  pode ser ou um objeto da classe “Image”, lido com o pacote *EBImage*, ou um caractere que indica o caminho para o arquivo da imagem (.jpg, .jpeg, .png, .tif) a ser analisada; *paper\_dim* representa o vetor numérico das dimensões (comprimento e largura – mm) do papel hidrosensível; *distance* é a distância do bico ao alvo para estimar a deriva da pulverização (%) usando o modelo alemão; *display.it* determina que se a imagem com a caixa delimitadora deve ser exibida.

### *analyzeImages*

A função *analyzeImages* detecta o papel hidrosensível em múltiplas imagens e faz todas as análises em uma execução. Exemplo de comando de execução:

```
> analyzeImages(path = "C:\\Users\\User\\Documents\\Imagens",  
                paper_dim = c(76, 26),  
                distance = 0.7,  
                display.it = FALSE)
```

Onde: *path* indica o caminho para o diretório onde as imagens (e apenas as imagens!) a ser analisadas estão alocadas; no comando de exemplo acima, a pasta “Imagens” exemplifica um diretório; *paper\_dim* representa o vetor numérico das dimensões (comprimento e largura – mm) do papel hidrosensível; *distance* é a distância (em metros) do bico ao solo (referência) para estimar o potencial de deriva (%) usando o Modelo Alemão (Rautmann et al., 2001); *display.it* determina que se a imagem com a caixa delimitadora deve ser exibida.

### *makeReport*

A função *makeReport* cria relatório em formato HTML com os resultados das análises de um ou mais papéis hidrosensíveis, incluindo a parte de análise gráfica de distribuição de gotas. Comando de execução:

```
> makeReport(x)
```

Onde *x* representa um objeto obtido com a função *analyzePaper()*.

## 5. CONCLUSÕES

Foi desenvolvido em linguagem R e testado quanto a performance nas estimativas de parâmetros de pulverização agrícola, o pacote *hydropaper*.

O pacote pode ser utilizado para analisar imagens de papéis capturadas a campo.

Em imagens capturadas apropriadamente o sistema conta com detector automático de papel hidrossensível com precisão superior a 75%.

Em imagens capturadas a campo o *hydropapper* foi mais eficaz que os demais sistemas em comparação.



## REFERÊNCIAS

ALVES T.C. **Otimização da tecnologia de aplicação de produtos fitossanitários na cafeicultura**. Tese – Doutorado em fitotecnia, Universidade Federal de Uberlândia, 2020.

ASAE S572.1. Spray nozzle classification by droplet spectra. **Am. Soc. Agric. Eng.**, p.4, 2009.

BAESSO, M. M., TEIXEIRA, M. M., RUAS, R. A. A., BAESSO, R. C. E. Tecnologias de aplicação de agrotóxicos. **Revista Ceres**, Viçosa, v. 61, p. 780-785, 2014.

BAY, H., TUYTELAARS, T., VAN GOOL, L. Speeded-up robust features (surf). **Comput. Vis. Image Underst.**, v.110, n.3, p.346–359, 2008.

BAY, H., TUYTELAARS, T., VAN GOOL, L. Surf: Speeded up robust features. In: **ECCV**, p.404–417, 2006.

BEYGELZIMER, A., KAKADET, S., LANGFORD, J., LI, S., Fast Nearest Neighbor Search Algorithms and Applications. 2019. Disponível em: < <https://cran.r-project.org/web/packages/FNN/FNN.pdf> >, Acesso em: 14 de dezembro de 2021.

BRANDOLI, B., SPADON, G., ESAU, T., HENNESSY, P., CARVALHO, A.C.P.L., AMER-YAHIA, S., RODRIGUES-JR, J.F. DropLeaf: A precision farming smartphone tool for real-time quantification of pesticide application coverage. **Computers and Electronics in Agriculture**, v.180, 2021.

CARVALHO, F.K., ANTUNIASSI, U.R., CHECHETTO, R.G., MOTA, A.A.B. Characteristics and challenges of pesticide spray applications in Mato Grosso, Brazil. **Outlooks on Pest Management**, Burckinghamshire, v.28, n.2, p.4-6, 2017.

CHAIM, A., CAMARGO NETO, J., PESSOA, M. C. P. Y. **Uso do programa computacional Gotas para avaliação da deposição de pulverização aérea sob diferentes condições climáticas**. Jaguariúna: Embrapa Meio Ambiente, p. 18, 2006.

COSTA, G.M. Guia prático de tecnologia de aplicação de herbicida e segurança no trabalho na cultura da cana de açúcar. Alvo consultoria em tecnologia de aplicação, p.37, 2019.

CUNHA, G., OLIVEIRA, C. A. A., ALVES, T. C., LIMA, L. P., CUNHA, J. P. A. R. Influência de pontas de pulverização e adjuvante na tecnologia de aplicação de fitossanitários na cultura do feijoeiro. **Enciclopedia Biosfera**, v. 17, n. 34, pg. 205, 2020.

CUNHA, J. P. A. R., FARNESE, A.C., OLIVET, J. J. Computer Programs for Analysis of droplets sprayed on Water Sensitive papers. **Planta Daninha**, v. 31, n. 3, p. 715-720, 2013.

CUNHA, M., CARVALHO, C., MARCAL, A. R. S. Assessing the ability of image processing software to analyze spray quality on water-sensitive papers used as artificial targets. **Biosystems Engineering**, v. 111, n.1, pg. 11-23, 2012.

EMBRAPA, **Gotas - Programa de Calibração de Pulverização – Gotas**, Embrapa Meio Ambiente Embrapa, Agricultura Digital, 2000.

FAVERO, A.L.F., GARCIA, L.C., JUSTINO, A., CANTERI, M.G., ROCHA, J.C.F. Software para análise de cartões hidrossensíveis. **Revista Brasileira de Agrocomputação**. v. 1, n. 1, p.45, 2001.

FERGUSON, J. C., HEWITT, A. J., O'DONNELL, C. C. Pressure, droplet size classification, and nozzle arrangement effects on coverage and droplet number density using air-inclusion dual fan nozzles for pesticide applications. **Crop Protection**, v. 89, p.231-238. 2016a.

FERGUSON, J.C., CHECHETTO, R.G., O'DONNELL, C.C., FRITZ, B.K., HOFFMANN, W.C., COLEMAN, C.E., CHAUHAN, B.S., ADKINS, S.W., KRUGER, G.R., HEWITT, A.J. Assessing a novel smartphone application – SnapCard, compared

to five imaging systems to quantify droplet deposition on artificial collectors. **Comput. Electron. Agric.** v.128, p.193–198, 2016b.

FOX, R. D., DERKSEN, R. C., COOPER, J. A., KRAUSE, C. R., & OZKAN, H. E. Visual and image system measurement of spray deposits using water-sensitive paper. **Applied Engineering in Agriculture**, v. 19, pg. 549-552, 2003.

GARCIA, L. C., RAMOS, H. H., JUSTINO, A. Avaliação de software para análise de parâmetros da pulverização realizada sobre papéis hidrossensíveis. **Revista Brasileira de Agrocomputação**, v. 2, n. 1, p. 19-28, 2004.

GANZELMEIER, H., RAUTMANN, D., SPANGERBERG, R., STRELOKE, M., HERRMANN, M., WENZELBURGER, H.J., WALTER, H.F. **Studies on the spray drift of plant protection products**. Results of test carried out throughout the Federal Republic of Germany, Federal Biological Center for agriculture and forestry, p.111, 1995.

GEORGE B. T. **Cálculo volume 2**, Person (Décima Edição 2002(adaptado))

GODINHO JUNIOR, J.D., VIEIRA, L. C., PEREIRA, L. O. A., RUAS, R. A. A., FARIA, V. R., FILHO, A. C. Deriva do herbicida 2,4-d aplicado com pontas hidráulicas de jato plano tipo leque. **Revista Brasileira de Ciências Agrárias**, v. 12, n. 4, p. 550-554, 2017a.

GODINHO JÚNIOR, J.D., GONTIJO, G.A., RUAS, R.A.A., SOUZA JÚNIOR, J.M.S., BARBOSA, W.G. Comparativo de três diferentes softwares utilizados para analisar imagens de manchas de gotas de pulverização mostra diferenças e semelhanças nos resultados obtidos. **Revista Cultivar**. Ano XIV, n 168, ISSN 1676 0158, 2017b.

GONZALEZ, R.C., WOODS, R.E. **Digital Image Processing**. Pearson Prentice Hall, 3rd. Edition, 2007.

KUHN, M., WING, J., WESTON, S., WILLIAMS, A., KEEFER, C., ENGELHARDT, A., COOPER, T., MAYER, Z., KENKEL. B., BENESTY, M., LESCARBEAU, R.,

ZIEM, A., SCRUCICA, L., TANG, Y., CANDAN, C., HUNT, T. Classification and Regression Training. 2021. Disponível em: < <https://cran.r-project.org/web/packages/caret/index.html> >, Acesso em: 14 de dezembro de 2021.

HOFFMAN, W. C., HEWITT, A. J. Comparison of three imaging systems for water sensitive papers. **ASABE, Applied Engineering in Agriculture**, St. Joseph, MI, v. 21, n. 6, p. 961-964, 2005.

LEON SISTEMAS DIGITAIS, DropScan, [s/d]. Disponível em: <<http://www.dropscan.com.br/>>, Acesso em: 14 de Dezembro de 2021.

LIBERATO, J.R. **Desenvolvimento e avaliação do software Quant para quantificação de doenças de plantas por análise de imagens**. Tese – Doutorado, Universidade Federal de Viçosa, 2003.

LOWE, D.G. Object Recognition from Local Scale-Invariant Features. **Proc. of the International Conference on Computer Vision**, 1999.

MACHADO, B.B., SPADON, G., ARRUDA, M.S., GONCALVES, W.N., CARVALHO, A.C.P.L.F., RODRIGUES-JR, J.F. A smartphone application to measure the quality of pest control spraying machines via image analysis. **Assoc. Comput. Mach.** 2018. <https://doi.org/10.1145/3167132.3167237>. ISBN 978-1-4503-5191-1/18/04.

MARTINS, J.G. **“Identificação de Espécies Florestais utilizando Seleção Dinâmica de Classificadores no Espaço de Dissimilaridade”**. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, 2014.

NANSEN, C., FERGUSON, J.C., MOORE, J., GROVES, L., EMERY, R., GAREL, N., HEWITT, A. 2015. Optimizing pesticide spray coverage using a novel web and smartphone tool, SnapCard. **Agron. Sustain. Dev.** 35, 1075–1085, 2018.

OLIVEIRA, B. A.S., ASSIS, S., SASAKI, R.S. Aplicativo android para avaliar a qualidade da pulverização em condições de campo. **Revista Engenharia e Tecnologia Aplicada**. v.2, n.1, 2018.

OTSU, N. A Threshold Selection Method from Gray-Level Histograms. **IEEE Transactions on Systems Man, and Cybernetics**, v.9, n.1, pg. 62-66, 1979.

PAU, G., FUCHS, F., SKLYAR, O., BOUTROS, M., HUBER, W. EBImage - an R package for image processing with applications to cellular phenotypes. **Bioinformatics**, v.26, n.7, p. 979-981, 2010.

R CORE TEAM (2021). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <https://www.R-project.org>.

RAMOS, H., SANTOS, J. M. F., ARAUJO, R. M., SANTIAGO, T. **Manual de tecnologia de aplicação de produtos fitossanitários**. Associação nacional de defesa vegetal, 2010.

RAUTMANN, D., M. STRELOKE, R. WINKLER, R. New basic drift values in the authorization procedure for plant protection products. 2001. In: FORSTER, R. & STRELOKE, M., **Workshop on Risk Assessment and Risk Mitigation measures in the context of the authorization of plant protection products (WORMM)** p.27-29. 1999. Mitteilungen aus der Biologischen Bundesanstalt für Land- und Forstwirtschaft, p.133-141, 2001.

RODRIGUES, M. B., CUNHA, J. P. A. R., ALVES, G. S. Estudo do espectro de gotas produzidas nas pulverizações aérea e terrestre na cultura da batata. **Revista de Ciências Agrárias**, v.54, n.3, p.225 -234, 2011.

SPRAYX, Dropscope. 2021. Disponível em: <<https://www.sprayx.com.br/>>, Acesso em: 22 de dezembro de 2021.

SCHNEIDER, C. A., RASBAND, W. S., ELICEIRI, K. W. NIH Image to ImageJ: 25 years of image analysis. **Nature Methods**, v.9, n.7, p.671–675, 2012.

TURNER, C. R., HUNTINGTON, K. A. The use of water sensitive dye for the detection and assessment of small spray droplets. **Journal of Agricultural Engineering Research**, v. 15, n. 4, p. 385-287, 1970.

WIJFFELS, J. Image.dlib: Image Processing Functionality using the 'dlib' Package. R package version 0.1.0, 2020.

WOEBBECKE, D. M. et al. Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the American Society of Agricultural Engineers**, v. 38, n. 1, p. 259–269, 1995.

ZHU, H., SALYANI, M., FOX, R. D. A portable scanning system for evaluation of spray deposit distribution. **Computers and Electronics in Agriculture**, v. 76, p. 38-43, 2011.