



UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA AGRÍCOLA

BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA

BRUNO SOUZA CERQUEIRA

**AVALIAÇÃO DE MÉTODOS DE SEGMENTAÇÃO DE
IMAGENS PARA DETECÇÃO DE PLANTAS**

CAMPINAS

2020



UNICAMP

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA AGRÍCOLA

BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA

BRUNO SOUZA CERQUEIRA

AVALIAÇÃO DE MÉTODOS DE SEGMENTAÇÃO DE IMAGENS PARA DETECÇÃO DE PLANTAS

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de **Bacharel em Engenharia Agrícola** à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

Orientador: Angel Pontin Garcia

CAMPINAS

2020



UNICAMP

AVALIAÇÃO DE MÉTODOS DE SEGMENTAÇÃO DE IMAGENS PARA DETECÇÃO DE PLANTAS

BRUNO SOUZA CERQUEIRA

BANCA EXAMINADORA

Angel Pontin Garcia

Juliana Aparecida Fracarolli

Rodrigo Leme de Paulo

Resumo

CERQUERA, B. S. **Avaliação De Métodos De Segmentação De Imagens Para Detecção De Plantas**. 2020 Trabalho de Conclusão de Curso (TCC) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2020.

A evolução da agricultura tem requerido o uso de avançadas tecnologias, dentre elas se encontra a visão computacional. Aplicações como irrigação, fertilização e controle de pragas são apenas alguns dos cenários que essa tecnologia pode atender. Entretanto, a demanda por sistemas acessíveis e eficientes aliada às inconstâncias e ruídos visuais de um ambiente externo, apresentam desafios a estes processos. Foi proposto nesse trabalho analisar e avaliar dez modelos de classificação de imagens e então eleger aquele que apresentar a melhor performance quanto a classificação de mudas de rúcula. Para o desenvolvimento do trabalho, foram coletadas 15 imagens ao longo do ciclo de vida das plantas e então aplicadas as abordagens estudadas. Os resultados obtidos mostraram que o formato e a distribuição das plantas na imagem têm interferência na acurácia dos modelos e também o tempo de processamento é um fator que deve ser levado em consideração ao escolher um modelo de segmentação de imagens.

Palavras-Chave: Detecção de plantas. Processamento de imagens. Segmentação por cor.

Abstract

CERQUERA, B. S. Avaliação De Métodos De Segmentação De Imagens Para Detecção De Plantas. 2020 Trabalho de Conclusão de Curso (TCC) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2020.

The evolution of agriculture has required the use of advanced technologies, among them is the computational vision. Applications such as irrigation, fertilization and pest control are only some of the scenarios that this technology can meet. However, the demand for accessible and efficient systems allied to the inconstancy and visual noise of an external environment, present challenges to these processes. It was proposed in this work to analyze and evaluate ten models of image classification and then to elect the one that presents the best performance regarding the classification of arugula seedlings. For the development of the work, 15 images were collected along the life cycle of the plants and then applied the studied approaches. The results obtained showed that the format and distribution of the plants in the image have interference on the accuracy of the models and also the processing time is a factor that should be taken into consideration when choosing a model of image segmentation.

Keywords: Plant detection. Image processing. Color segmentation.

Sumário

1. Introdução	7
2. Justificativa	8
3. Objetivos	8
4. Revisão Bibliográfica	8
5. Materiais e Métodos	10
5.1. Hardware e Software	10
5.2. Características Experimentais	11
5.3. Métricas	12
6. Resultados	16
6.1. Aplicação	19
7. Conclusão	19
8. Referências Bibliográficas	21

1. Introdução

A evolução da agricultura direcionada à sustentabilidade, exige participação no avanço tecnológico quando se almeja, além de uma agricultura saudável, uma agricultura eficiente em termos econômicos. O processamento de imagens, atrelado à agricultura de precisão a qual integra essa tecnologia, traz melhores produtividades para produtores agrícolas, reduzindo erros no processo e custos para atingir resultados ecologicamente sustentáveis (VIBHUTE e BODHE, 2012).

O processamento de imagens consiste em aplicar filtros e realizar operações matemáticas para que seja possível eliminar ruídos, encontrar ou destacar objetos de interesse. Podem ser extraídos da imagem parâmetros como cor, forma, tamanho e textura, porém grande parte das aplicações do processamento de imagens tem como objetivo identificar elementos para análises subsequentes. Esse reconhecimento pode ser obtido por meio da segmentação de imagens digitais a qual, segundo Horgan e Glasbey (1994), consiste-se na divisão dessas imagens em regiões ou categorias as quais correspondem a um objeto ou uma parte deste objeto.

Devido à facilidade de acesso a câmeras com aquisição de imagens coloridas, o método de segmentação por cor tem ganhado considerável espaço no contexto do processamento de imagens, quando comparado às abordagens de segmentação por textura e forma (TIAN e SLAUGHTER, 1998). No ambiente agrícola, ele é bastante explorado com o intuito de identificar mudas de plantas e até mesmo ataques de pragas, diferenciando as plantas do solo e de outros materiais, graças à diferença de cores (TANG et al, 1998).

Dada a heterogeneidade do ambiente agrícola, esses métodos de segmentação ainda apresentam deficiências, principalmente no que tange à iluminação. Para corrigir os erros devido a isso, técnicas de processamento de imagens e algoritmos têm sido desenvolvidos e aprimorados, visando eliminar os ruídos associados às condições do ambiente e extrair apenas as informações úteis da imagem (TIAN e SLAUGHTER, 1998). Ainda assim, não foi possível alcançar uma solução universal para o problema.

Peressini (2018) desenvolveu um trabalho cujo objetivo era selecionar alternativas de softwares que apresentassem baixo custo computacional para detecção de mudas de plantas no meio agrícola. Foram analisados vinte e seis modelos de classificação de imagens e então elegidos dez modelos de segmentação que aprestaram o melhor desempenho sob os critérios de avaliação: tempo de processamento e erros de detecção ao longo de cinco experimentos

utilizando mudas de Morango, Hortelã, Manjeriçã, Soja e Milho sob diferentes condições de iluminação.

2. Justificativa

A partir do fato de que cada situação no âmbito do processamento de imagens exige uma solução específica, isto é, uma solução universal não é viável, ainda existe a necessidade de se avaliar qual ou quais abordagens são as mais indicadas para a classificação de plantas em ambientes de cores não homogêneas. Então, surge esse trabalho com o intuito de eleger um modelo para a classificação de mudas de hortaliças.

3. Objetivos

Este projeto teve como objetivo avaliar, dentre as dez abordagens de classificação de imagens por segmentação indicadas por Peressini (2018) como as de maior performance no quesito classificação de mudas de plantas, um modelo que alcance, dada uma imagem contendo plantas e solo, a melhor segmentação entre solo e planta numa bancada experimental de rúcula sob os critérios: *Fscore*, Acurácia e tempo de processamento.

4. Revisão Bibliográfica

A segmentação de imagens digitais, segundo Horgan e Glasbey (1994), consiste-se na divisão de imagens em regiões ou categorias as quais correspondem a um objeto ou uma parte deste objeto. Para isso, os pixels são agrupados dentro dessas categorias e representam as suas características. Dentro de uma mesma categoria os pixels possuem valores semelhantes.

Estudos vêm sendo desenvolvidos utilizando essa metodologia com foco nos métodos de constância de cor, e com o intuito de mitigar o problema recorrente nas imagens devido às variações nas condições ambientais (intensidade luminosa e ruídos nas imagens). RATNASINGAM e MCGINNITY (2012) testaram modelos capazes de extrair a cromaticidade das imagens de forma eficiente, mesmo em ambientes com interferência da iluminação externa. Os algoritmos foram testados com base na separabilidade e perceptibilidade das cores em diferentes tipos de iluminações, e foram obtidos boa performance quando comparados com outros algoritmos apontados no trabalho. Por outro lado, GIJSENIJ, GEVERS e VAN DE WEIJER (2011) analisaram diferentes métodos de correlação de cor com baixos, médios e altos níveis estatísticos bem como os métodos *Gamu-based* e *Physics-Based*, avaliados por critérios tais como: custo computacional, acurácia da estimativa e a complexidade de implementação, concluindo que todos os modelos analisados possuem vantagens e desvantagens as quais são

critérios a serem considerados em futuras aplicações desses modelos em novas pesquisas. Há ainda um projeto desenvolvido por BIANCO; CUSANO; SCHETTINI, (2015) e OH e KIM, (2017) onde foram avaliados alguns algoritmos como *Grey World*, *White Patch*, dentre outros, por meio de redes neurais e convolução em ambientes de múltipla iluminação, obtendo menores erros de estimativa para o seu objetivo quando comparados a outros métodos de abrangência generalizada. Ainda assim não se pôde chegar a uma solução universal, isto é, uma única solução a qual fosse capaz de se adaptar a qualquer condição em qualquer imagem produzindo resultados eficientes.

Observando a existente oportunidade para o desenvolvimento de novas pesquisas e também novas estruturas de modelos com o intuito de tornar mais eficientes o uso das tecnologias presentes bem como a sua ampliação, Jafari et al (2014) desenvolveram um trabalho buscando identificar um modelo ideal de processamento de imagens para diferenciar flores de açafraão do solo onde elas são cultivadas e, com isso, tornar mais eficiente o processo de colheita dessas flores o qual, juntamente com o pós colheita, exigem uma intensa mão de obra humana (JAFARI et al, 2014) e constitui aproximadamente um terço do custo da produção dessa cultivar na região do Iran (NEGBI, 1999). As imagens RGB foram analisadas por meio dos modelos de cores HSV e YCrCb sob diferentes condições de iluminação. O valor *target* para a segmentação das imagens foram obtidos a partir do seu histograma de cores, observando os menores valores entre a saturação da imagem (H) e sua cromaticidade na banda azul (Cb). Para a classificação das imagens foram aplicadas redes neurais artificiais. Em seguida, a melhor classificação foi considerada aquela que apresentou o menor coeficiente de correlação e também o menor RMSE (Root Mean Square Error). Esses resultados mostraram que o modelo da cromaticidade apresentou acurácias melhores do que o HSV e que a aplicação das redes neurais artificiais torna o processo de classificação mais robusto no tocante a perda de dados e outros ruídos que podem afetar a qualidade das imagens.

Aureliano Neto et al. (2018) realizaram um trabalho onde avaliaram a eficiência de três diferentes índices de vegetação (ExG, ExGR e NDI) aplicados para diferenciar as folhas da planta e o solo, conjuntamente a diferentes modelos de *Thresholding* tais como *Otsu*, *Ridler* e *Triangle*, em imagens de uma cultura de milho com três diferentes coberturas de solo. Os três índices de vegetação foram testados com cada modelo de *Thresholding* por meio do algoritmo de agrupamento de dados *K-Means* onde o K significa o número de grupos de pixels em que a imagem será dividida e ele é um fator definido pelo usuário. Esse algoritmo seleciona os pixels da imagem segundo similaridades e características como intensidade de cor e a distância

relativa entre eles (DASS et al. 2012). Para a avaliação dos modelos foram levantados os parâmetros estatísticos ANOVA e coeficiente de variação (CV) de cada uma das amostras. Apesar dos desafios ocorridos pela variação da iluminação os resultados foram considerados satisfatórios para as condições analisadas, contudo, os modelos NDI e ExGR apresentaram melhores acurácias, quanto a segmentação de imagens RGB, quando comparados com o índice ExG.

Tao Cheng et al. (2018) realizaram um trabalho utilizando índices de vegetação tais como GNDVI (*Green Normalized Difference Vegetation Index*) (GITELSON et al. 1996), NExG (*Normalized Excess Green Index*) (RASMUSSEN et al., 2016), NGRDI (*Normalized Green-Red Difference Index*) (TUCKER, 1979) e ENDVI (*Enhanced Normalized Difference Vegetation Index*) em imagens obtidas por veículos aéreos remotamente pilotados (drones) equipados com sensores capazes de captar imagens compostas pelas bandas vermelha, verde e azul (RGB), imagens compostas por duas destas bandas e uma delas (a vermelha ou a azul) substituídas pela banda do infravermelho próximo (CIR) e também imagens multiespectrais (MS). Essa pesquisa foi desenvolvida com o intuito de encontrar o sensor ideal para estimar a quantidade de nitrogênio (N) presente, tanto na folha quando na planta em si, ao longo do desenvolvimento da cultura do arroz, o qual é compreendido pelos estágios de perfilhamento (a pós o transplante), de ajuntamento (desenvolvimento e maturação) e o momento onde se inicia a colheita. Ao analisar os resultados obtidos por meio de parâmetros como RMSE e R^2 , concluíram que o índice de vegetação NGRDI aplicado à imagem RGB mostrou satisfatórias estimativas das quantidades de N presentes nas folhas das plantas do arroz para as etapas de perfilhamento e ajuntamento, ao passo que o índice GNDVI aplicado à imagem CIR apresentou razoável performance para as três fases do desenvolvimento dessa cultura.

5. Materiais e Métodos

O presente trabalho foi executado no Laboratório de Instrumentação e Controle da Faculdade de Engenharia Agrícola da Unicamp. Nos tópicos a seguir serão detalhados os elementos e as considerações as quais tornaram possível a realização deste projeto.

5.1. Hardware e Software

Os instrumentos utilizados ao longo da execução deste projeto foram selecionados considerando critérios de acessibilidade e custo. Quanto a captura das imagens, A Figura 5.1 mostra o esquema da configuração da bancada experimental montada com área de cultivo de 1.125 m² (0,75m de largura e 1,5m de comprimento).O sensor ultrassom digital utilizado da

marca ElecFreaks, modelo HC-SR04, com faixa de operação entre 2mm e 4,00m e precisão de ± 3 mm, foi alocado na parte superior do *frame* da bancada, garantindo que as imagens fossem obtidas da mesma altura e, conseqüentemente, com o mesmo número de pixels. As imagens foram capturadas utilizando uma câmera digital 12MP (f/1.8, 28mm, 1/3”).

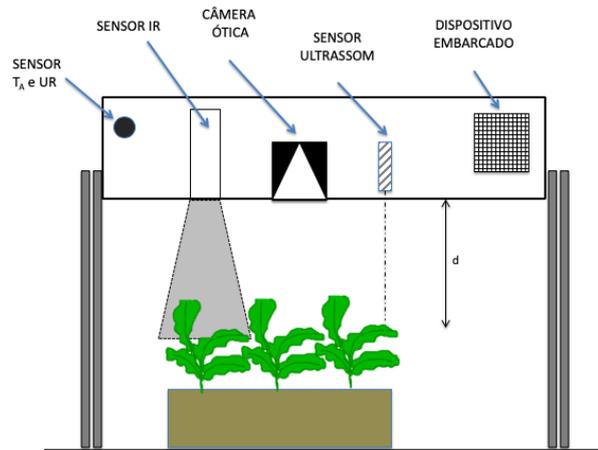


Figura 5.1 - Esquemática bancada montada.

Para o processamento das imagens, foi utilizado um *notebook* marca ACER, processador Intel Core i5 de 8ª Geração com 3,90 Ghz e 12GB de memória RAM com uma placa de vídeo NVIDIA GEFORCE MX 130 de 2GB. O algoritmo para a aplicação dos modelos nas imagens foi construído utilizando a linguagem de programação PYTHON, uma linguagem de relativo alto nível com grande flexibilidade, autonomia e poder computacional, além de altamente difundida e reconhecida. Esse algoritmo em Python conta com o uso das bibliotecas *Open-CV* para os comandos relacionados às manipulações das imagens, *Numpy* para a realização das operações matemáticas envolvida no processo e alguns comandos da biblioteca *Pandas* para agrupar e organizar os dados de saída (*outputs*) de cada modelo.

5.2. Características Experimentais

A cultura selecionada foi a Rúcula (*Eruca sativa Miller*) devido à distribuição homogênea no formato das folhas, onde se utilizou o espaçamento recomendado por Freitas et al. (2009), de 0,20m entre linhas e 0,05m entre plantas. A partir disso e dos materiais supracitados, 15 imagens foram capturadas em diferentes fases do desenvolvimento da cultura, com o intuito de que os modelos avaliassem as imagens com as plantas em diferentes tamanhos e formatos.

5.3. Métricas

Para a execução deste projeto, 10 modelos de classificação de imagens por segmentação por cor foram utilizados. Esses modelos foram selecionados com base no trabalho desenvolvido por Peressini (2018), onde foram avaliados 26 modelos de classificação de imagens e então selecionados os 10 com maior performance segundo os critérios de tempos de processamento e erros de detecção. Essas abordagens podem ser vistas na Tabela 5.3.

Tabela 5.3. Modelos de segmentação para análise

ID	Abordagens
1	HSV intervalo
2	HSV (t)
3	CrCbCg (Cg)
4	CrCbCg (Excess Green)
5	Excess Green (RGB)
6	YCrCb (Cr+Cb)
7	$L*u*v*(u*-v*)$
8	$L*a*b*(b*-a*)$
9	NDI manual
10	L1L2L3 (L3)

Onde o ID1 representa o modelo HSV o qual propõe a dissociação do elemento acromático de uma imagem (Valor) de elementos que carregam as informações de cor (Matiz e Saturação), proporcionando uma melhor percepção das cores. Os parâmetros que descrevem este modelo são:

- *Hue* (Matiz): É um atributo de cor que descreve uma cor pura, como vermelho, laranja, verde. Ele indica o tipo de cromaticidade que a cor possui.
- *Saturation* (Saturação): É uma medida que representa o grau de pureza de determinada cor, ou o quanto diluído a cor pura se encontra na luz branca.
- *Value* (Valor): É a grandeza responsável por mensurar a intensidade da luz que indica a noção acromática de brilho. Sua representatividade é a mesma das imagens em escala cinza.

Dada uma imagem em RGB, a conversão para o modelo HSV pode ser feita, considerando que os valores estão normalizados (intervalo entre 0 e 1), por meio das seguintes fórmulas para cada pixel:

1. *Value:*

$$V \leftarrow \max(R, G, B) \quad \text{Equação 1}$$

2. *Saturaton:*

$$S \leftarrow \begin{cases} \frac{V - \min(R, G, B)}{V} & \text{se } V \neq 0 \\ 0 & \text{caso contrário} \end{cases} \quad \text{Equação 2}$$

3. *Hue:*

$$H \leftarrow \begin{cases} 60(G - B)/(V - \min(R, G, B)) & \text{se } V = R \\ 120 + 60(B - R)/(V - \min(R, G, B)) & \text{se } V = G \\ 240 + 60(R - G)/(V - \min(R, G, B)) & \text{se } V = B \end{cases} \quad \text{Equação 3}$$

O ID2 também apresenta a mesma abordagem (HSV), porém, a sua limiarização foi realizada pelo método Otsu¹, ao passo que o limiar da primeira foi obtido a partir do histograma calculado para a imagem HSV, isto é, a imagem gerada após a conversão.

O método CrCbCg (Cg), representado pelo ID3, é derivado do modelo YCrCb o qual é largamente utilizado como modelo de caracterização de cores de imagens (TIAN-HUAI e XIN,2010) por considerar os efeitos de luminosidade (Y) e cromaticidade (Cr e Cb), onde o Cr é proveniente da banda R, o Cb da banda B e, para formar um cubo de cores relacionando as três, têm-se o Cg o qual é derivado da banda G. As equações as quais tornam possíveis a conversão de uma imagem RGB em CrCbCg são:

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ -0,169 & -0,331 & 0,50 \\ 0,50 & -0,419 & -0,081 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad \text{Equação 4}$$

$$Cg = 0,50 - 0,362R + 0,50G - 0,138B \quad \text{Equação 5}$$

A diferença existente entre o modelo ID3 e o modelo ID4 se dá pelo fato de que no CrCgCb(Cg) utilizou-se a abordagem da cromaticidade derivada da banda G (Cg) aplicada na imagem CrCgCb e no outro, aplicou-se o índice *Exces Green* nesta mesma imagem. Vale lembrar que, para ambos as abordagens (ID 3 e ID 4) o limiar foi determinado por meio do histograma gerado para cada *output*.

A avaliação de índices de vegetação feitas por Woebbecke et al. (1995), trouxe bons resultados quanto a geração de imagens quase binárias por meio do índice de vegetação *Excess Green* (ID5), o qual é representado pela Equação 6 e se tornou bastante citado em outros estudos

¹ O método de Otsu requer apenas os valores do histograma da imagem, isto é, uma representação da quantidade de pixels em cada nível de intensidade para determinar o seu limiar ótimo (OTSU, 1979).

(PERESSINI, 2018). A limiarização nesse caso, seguiu o mesmo esquema da abordagem predecessora.

$$ExG = (2G) - R - B \quad \text{Equação 6}$$

O ID6 apresenta um modelo já mencionado, porém aplicados com a abordagem das cromaticidades provenientes das bandas de cor verde e azul. A imagem, resultado da aplicação desse modelo (YCrCb) na imagem RGB normalizada, foi binarizada segundo o valor *target* gerado por meio do seu histograma.

As abordagens apresentadas pelos IDs 7 e 8, $L^*u^*v^*(u^*-v^*)$ e $L^*a^*b^*(b^*-a^*)$ respectivamente, são conhecidas como espaços de cor uniformes devido às suas diferenças nas coordenadas de cores corresponderem à mesma percepção visível do tom e saturação das cores (KOSCHAN; ABIDI, 2008). Nos dois modelos existe a separação da representação das cores com a luminosidade, sendo, nesse caso, representado pela letra L^* . No espaço $L^*a^*b^*$, o canal a^* representa o eixo verde-vermelho, e o canal b^* o eixo azul-amarelo. Já para o modelo $L^*u^*v^*$ os canais u^* e v^* são definidos como transformações não-lineares de X e Y^2 respectivamente (GARCÍA-MATEOS et al., 2015). O limiar para esses modelos foi calculado segundo o método de Otsu. As equações para essa conversão seguem:

$$L \leftarrow \begin{cases} 116 * Y^{\frac{1}{3}}, & Y > 0,008856 \\ 903,3 * Y, & Y \leq 0,008856 \end{cases} \quad \text{Equação 7}$$

$$\begin{aligned} a &\leftarrow 500(f(X) - f(Y)) \\ b &\leftarrow 200(f(Y) - f(Z)) \end{aligned} \quad \text{Equação 8}$$

$$f(t) = \begin{cases} t^{\frac{1}{3}}, & t > 0,008856 \\ 7,787t + 16/116, & x \leq 0,008856 \end{cases} \quad \text{Equação 9}$$

$$\begin{aligned} u' &\leftarrow 4 * X / (X + 15Y + 3Z) \\ v' &\leftarrow 9 * Y / (X + 15Y + 3Z) \end{aligned} \quad \text{Equação 10}$$

$$\begin{aligned} u &\leftarrow 13 * L * (u' - u_n) \quad \text{onde } u_n = 0,19793943 \\ v &\leftarrow 13 * L * (v' - v_n) \quad \text{onde } v_n = 0,46831096 \end{aligned} \quad \text{Equação 11}$$

O índice de vegetação NDI (Normalized Vegetation Index), indicado pelo ID9, proposto por Perez et al. (2000), leva em consideração as bandas de cores vermelho e verde. O limiar para esta abordagem foi definido a partir do histograma da imagem NDI. Esse modelo pode ser

² Desenvolvido em 1931 pela Comissão Internacional de Iluminação (CIE-Commission internationale de l'éclairage), é o modelo constituído pelos valores de tri-estímulos conhecidos como XYZ, constitui a base dos modelos tricromáticos e de diversos outros espaços de cor (KOSCHAN; ABIDI, 2008).

calculado a partir da Equação 12.

$$NDI = \frac{G-R}{G+R} \quad \text{Equação 12}$$

O último método mostrado na Tabela 1 (ID10) denominado L1L2L3 (L3), foi proposto e testado por Gevers e Smeulders (1999) e foi desenvolvido com intuito de criar um modelo invariante à luminosidade quando aplicados a objetos tanto foscos quanto brilhantes, reduzindo os efeitos de destaques luminosos, orientação da superfície e também à variações de intensidade da luz incidente (PERESSINI, 2018). Para este projeto a sua limiarização foi realizada baseada nos dados do histograma da imagem l1l2l3. Suas formulações são apresentadas nas Equações 13, 14 e 15.

$$l1 = \frac{(R-G)^2}{(R-G)^2+(R-B)^2+(G-B)^2} \quad \text{Equação 13}$$

$$l1 = \frac{(R-B)^2}{(R-G)^2+(R-B)^2+(G-B)^2} \quad \text{Equação 14}$$

$$l1 = \frac{(G-B)^2}{(R-G)^2+(R-B)^2+(G-B)^2} \quad \text{Equação 15}$$

A avaliação das abordagens foi realizada por meio da métrica *F-score* (Equação 19), definida por Peressini (2018) como a média harmônica entre a precisão (Equação 17) e sensibilidade (Equação 18). Essa métrica quantifica, de forma robusta, entre 0 e 1 a classificação das imagens, sendo 0 a ausência de Verdadeiros Positivos e 1 a classificação perfeita.

$$Erro\ total = \frac{FP+FN}{VP+VN+FP+FN} \quad \text{Equação 16}$$

$$Precisão = \frac{VP}{VP+FP} \quad \text{Equação 17}$$

$$Sensibilidade = \frac{VP}{VP+FN} \quad \text{Equação 18}$$

$$Fscore = 2 * \frac{Precisão*Sensibilidade}{Precisão+Sensibilidade} = \frac{2VP}{2VP+FP+FN} \quad \text{Equação 19}$$

Onde VP são as classificações verdadeiras positivas, VN são as classificações verdadeiras negativas, FP são as classificações falsas positivas e FN são as classificações falsas negativas. As imagens usadas como referência para determinar se a classificação está ou não correta foram manualmente classificadas, ou seja, manualmente ajustadas de forma que todos

os pixels que apresentaram a coloração da planta recebeu o valor 1 e, conseqüentemente, o que não era planta, ficou com o número 0. Ainda de acordo com Peressini (2018), o erro total (Equação 16) significa a proporção de avaliações incorretas no total de avaliações realizadas, a precisão (Equação 17) representa a quantidade de classificações corretas positivas em relação ao total de classificações positivas e a sensibilidade (Equação 18), por sua vez, representa a quantidade de classificações positivas corretas em relação aos pixels os quais compõem as plantas. Além desse fator avaliativo, o tempo de processamento de cada abordagem também foi calculado, uma vez que ele é de suma importância no que tange a uma aplicação da classificação de imagens em tempo real.

Para a avaliação dos modelos, a imagem alvo, isto é, a imagem contendo os pixels corretos identificando as plantas (número 1) e o solo (número 0), foi determinada manualmente onde foram selecionados 10 pixels contendo valores de RGB correspondentes às cores que representam as plantas, em seguida foi calculada a média e o desvio padrão para cada imagem e então as imagens RGB foram binarizadas de forma que os valores dos pixels que se enquadrem no interior da faixa de valores correspondente à média subtraída e adicionada em um desvio e padrão ($[Média - Desvio Padrão]$, $[Média + Desvio Padrão]$).

Ao aplicar cada uma das abordagens supracitadas em cada imagem, foram obtidas 150 imagens binárias. Dessa forma, foram obtidos 150 valores, sendo 15 valores de $Fscore$, de acurácia e também de tempo de processamento o qual não considerou o tempo de leitura de cada imagem, devido a este ser considerado constante à todas imagens. A partir desses números, foram calculadas as respectivas precisões da classificação de cada um dos modelos, dadas as variações nas imagens, ou seja, o quão consistente é o resultado apresentado por cada um dos 10 modelos de classificação de imagens avaliados.

6. Resultados

As 15 imagens foram processadas, para cada uma foram geradas 10 novas imagens binárias, isto é, cada modelo resultou uma imagem *output*. As imagens foram capturadas em diferentes fases da cultura, onde pôde-se observar os diferentes formatos das plantas e com isso, avaliar a robustez dos métodos em estudo. A Figura 6.1 mostra duas das imagens utilizadas para alimentar o algoritmo e assim avaliar os 10 modelos. Nota-se facilmente na Figura 6.1 a diferença entre a densidade de plantas e também as diferenças presentes na coloração do solo onde elas estão plantadas.



Figura 6.1 – Exemplo de Imagens RGB de Rúcula utilizada.

Aplicando os conjuntos de Equações 1 a 19 as quais são responsáveis por compor os modelos de segmentação de imagens, objetos de estudo desse projeto, na matriz base das imagens e comparando-as com as imagens *targets*. Estas produzidas a partir da metodologia supracitada onde se resultou em imagens como a mostrada na Figura 6.2. A partir disso, foram obtidos 15 valores de *Fscore* e acurácia para cada abordagem.



Figura 6.2 – Exemplo das imagens *target* utilizadas.

Os valores médios e as suas respectivas precisões, resultantes de cada um dos modelos estudados, estão apresentados na Tabela 6.1.

Tabela 6.1. Parâmetros de classificação de cada modelo.

ID	Abordagens	Limiarização	Fscore [%]	Acurácia [%]	Tempo [s]
1	HSV intervalo	Média Hist.	81,8 ± 3	84,0 ± 5	7,1 ± 0,3
2	HSV (t)	Otsu	81,8 ± 3	84,0 ± 5	7,1 ± 0,4
3	CrCbCg (Cg)	Média Hist.	87,0 ± 3	90,2 ± 3	5,2 ± 0,2
4	CrCbCg (Excess Green)	Média Hist.	87,0 ± 2	90,9 ± 2	5,2 ± 0,2
5	Excess Green (RGB)	Média Hist.	86,3 ± 2	90,8 ± 2	0,5 ± 0,03
6	YCrCb (Cr+Cb)	Média Hist.	82,9 ± 9	89,5 ± 1	5,3 ± 0,2
7	$L^*u^*v^*(u^*-v^*)$	Otsu	85,5 ± 3	88,7 ± 3	17,5 ± 0,8
8	$L^*a^*b^*(b^*-a^*)$	Otsu	85,4 ± 3	88,8 ± 3	9,5 ± 0,4
9	NDI manual	Média Hist.	77,2 ± 11	83,5 ± 6	0,8 ± 0,1
10	L1L2L3 (L3)	Média Hist.	78,8 ± 4	80,3 ± 9	1,9 ± 0,1

Ao observar os dados mostrados na Tabela 6.1, pode se notar que os valores do *Fscore* variam entre 77,2% e 87%. Esses valores representam a capacidade do modelo em acertar os pixels onde existem partes da planta dentro da imagem, ou seja, ele não leva em consideração os valores, também corretos, porém classificados como solo. Ao considerar tanto os pixels corretos preditos como sendo solo e os pixels corretos preditos como planta, obtêm-se a acurácia do modelo. A Tabela 6.1 mostra que os modelos classificaram as imagens com uma acurácia variando de 80,3% até 90,9%, isto é, as abordagens demonstraram razoável variabilidade em termos da capacidade de classificação das imagens, sendo aquela que mostrou maior *Fscore* e, conseqüentemente, maior acurácia foi aquela representada pelo ID 4, ou seja, o modelo CrCbCg(Excess Green) com $90.9 \pm 3\%$ de acurácia e um *Fscore* de $87 \pm 2\%$. Dentre as abordagens testadas, aquela que apresentou pior desempenho considerando os fatores avaliativos *Fscore* e acurácia, foi o modelo NDI(manual), com um *Fscore* de $77.2 \pm 11\%$ e acurácia de $83.5 \pm 6\%$. Além da pior performance dentre os modelos, esta abordagem apresentou grande imprecisão dentre seus resultados, isto é, o modelo NDI(manual) mostrou grandes variações ao classificar as 15 imagens quando comparado aos outros modelos estudados neste projeto. É válido mencionar que a abordagem representada pelo ID 10 mostrou a menor acurácia dentre os modelos, porém, ela apresentou um *Fscore* acima de 78% com uma precisão maior que aquela resultante do modelo representado pelo ID 9. Por isso, o L1L2L3 não foi apontado como o modelo de menor performance.

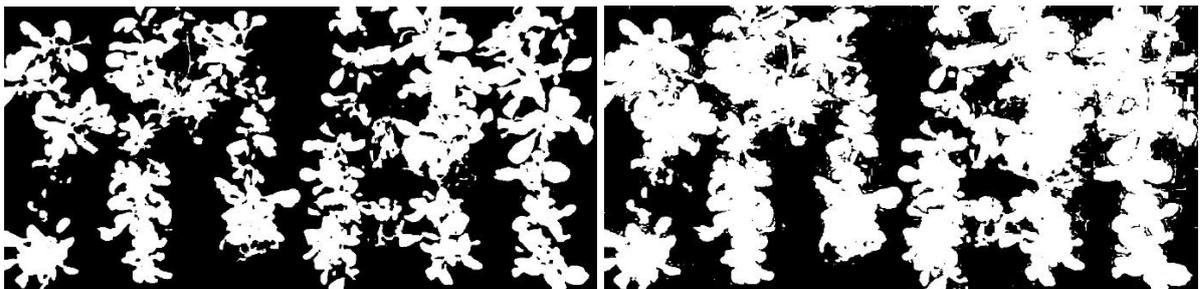


Figura 6.2 – Imagens *outputs*. Esquerda: Modelo CrCbCg(Excess Green), Direita: modelo NDI(manual).

Ao observar as imagens mostrada na Figura 6.2, pode-se identificar facilmente as diferenças na classificação apresentada por cada abordagem. Vale lembrar que a Figura 6.1 mostra duas imagens *output* resultado da mesma imagem *input*. Na imagem *output* da esquerda, nota-se uma maior precisão quando comparada ao *output* do lado direito. Essa diferença de precisão resultou na inferior performance do modelo NDI(manual), pois apresentou um maior número de falsos positivos (FP).

Outro critério avaliado em cada abordagem, foi o tempo de processamento levado para

classificar as imagens. Esse critério foi obtido seguindo o mesmo raciocínio dos outros fatores avaliativos, onde para cada modelo foi calculado um tempo de processamento, resultando em 15 valores. Desse montante, calculou-se a média para cada uma das abordagens, esta que é mostrada na Tabela 6.2 (última coluna). Esse critério é um fator decisivo quando se deseja classificar imagens em tempo real, uma vez que a operação em tempo real não permite espera quanto à classificação, ou seja, a tomada de decisão deve ser feita instantaneamente após a captura da imagem. Levando em consideração esse critério, o modelo de maior performance é aquele representado pelo ID 5, ou seja, o *Excess Green* (RGB), o qual apresentou o menor tempo de processamento, $0,5 \pm 0,03s$. Apresentou o segundo maior *Fscore*, $86,3 \pm 2\%$ e, por conseguinte, uma acurácia de $90,8 \pm 2\%$. Por outro lado, a abordagem que apresentou o pior desempenho, quanto ao tempo de processamento, foi o modelo $L*u*v*(u*-v*)$, o qual levou uma média de $17,5 \pm 0,8s$ para classificar cada uma das imagens. Essa quantidade de tempo, torna esse modelo inviável para uma possível aplicação em um sistema de classificação de imagens em tempo real. Além disso, sua acurácia não alcançou os 90%, ou seja, mesmo não levando em conta o tempo de processamento, neste projeto, ele não seria escolhido como o melhor classificador de imagens para detecção de plantas.

Vale lembrar que o tempo de processamento é um fator diretamente proporcional ao poder computacional da máquina a qual está executando os algoritmos responsáveis pela aplicação dos modelos às imagens. Nesse contexto, esse fator foi inserido neste projeto como critério avaliativo, a fim de comparar a performance de cada modelo em termos da diferença de tempo entre eles, e não explicitando a média de tempo de processamento requerida para cada uma das 10 abordagens estudadas.

6.1. Aplicação

Aplicando um mapa de temperatura à uma das imagens obtidas neste projeto, obtém-se uma imagem com a escala de temperatura a qual se encontram as plantas nela presentes. A Figura 6.1.1 mostra esse resultado, indicando que esse processo pode ser utilizado para detecção de *stress* hídrico em plantas. Onde é possível focar somente nas plantas, visto que a imagem foi segmentada e processada a fim de distinguir os pixels contendo solo daqueles que representam as plantas.

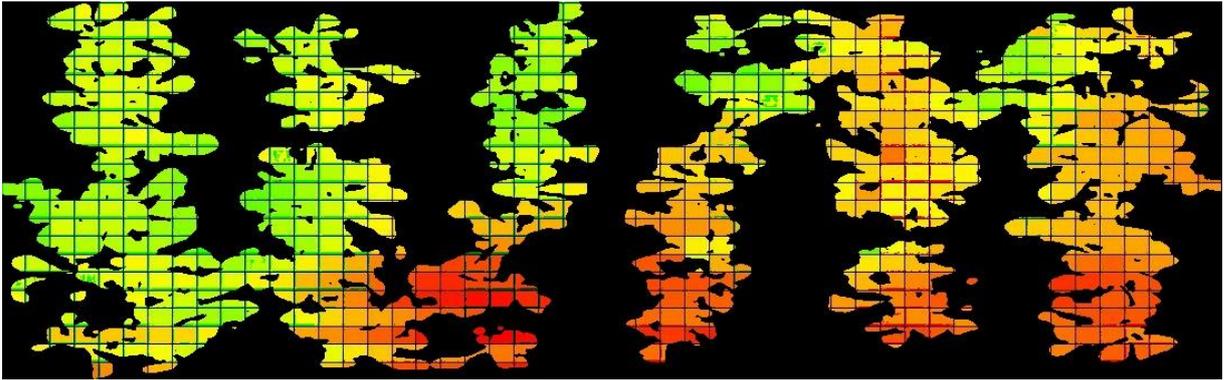


Figura 6.1.1 – Exemplo da imagem resultante da aplicação de um mapa de temperatura à imagem binária

7. Conclusão

A partir dos resultados obtidos, foi possível identificar o modelo de classificação que apresentou a melhor performance considerando o critério de avaliação *Fscore*. O maior valor para esse critério dentre os 10 modelos foi o CrCbCg(Excess Green), de $87 \pm 2\%$. No entanto, essas abordagens foram também avaliadas pelo seu tempo de processamento. Dessa forma, houve um modelo que alcançou o terceiro maior *Fscore* ($86,3 \pm 2\%$) porém um tempo de processamento 10 vezes menor do que o CrCbCg(Excess Green). Como a diferença entre os valores do *Fscore* para esses dois modelos está dentro da margem de erro, o tempo de processamento foi o fator decisivo para a escolha do melhor modelo. Assim, a abordagem representada pelo ID 5, Excess Green (RGB), foi eleita como a de melhor performance dentre os 10 modelos estudados e avaliados neste projeto.

8. Referências Bibliográficas

- AGARWAL, V. et al. **An Overview of Color Constancy Algorithms.** *Journal of Pattern Recognition Research*, v. 1, p. 42–54, 2006.
- AURELIANO NETO A. F et al. **Segmentation of RGB images using different vegetation indices and thresholding methods.** *Nativa, Sinop*, v. 6, n. 4, p. 389-394, jul./ago. 2018.
- BIANCO, S.; CUSANO, C.; SCHETTINI, R. **Color constancy using cnns.** arXiv preprint arXiv:1504.04548, 2015.
- DASS, R.; PRIYANKA. ; DEVI, S. **Image Segmentation Techniques.** *International Journal of Electronics & Communication Technology*, v. 3, n. 1, p. 1-5, 2012.
- FREITAS, K. K. C., NETO, F. B., GRANGEIRO, L. C., LIMA, J. S. S., MOURA, K. H. S. **Desempenho agronômico de rúcula sob diferentes espaçamentos e épocas de plantio.** *Revista Ciências Agrônômicas*, v. 40, n. 3, p. 449-454, 2009.
- GARCÍA-MATEOS, G. et al. **Study and comparison of color models for automatic image analysis in irrigation management applications.** *Agricultural Water Management*, Elsevier B.V., v. 151, p. 158–166, 2015. ISSN 18732283.
- GLASBEY C. A. and HORGAN G. W. **Image Analysis for the Biological Sciences.** Scottish Office Agriculture and Fisheries Department. Edinburgh, February 1994.
- GIJSENIJ, A.; GEVERS, T.; VAN DE WEIJER, J. **Computational color constancy: Survey and experiments.** *IEEE Transactions on Image Processing*, v. 20, n. 9, p. 2475–2489, 2011. ISSN 10577149.
- GITELSON, A.A.; KAUFMAN, Y.J.; MERZLYAK, M.N. **Use of a green channel in remote sensing of global vegetation from EOS-MODIS.** *Remote Sens. Environ.* 1996, 58, 289–298.
- JAFARI A., BAKHSHIPOUR A. and HEMMATIAN R. **Integration of Color Features and Artificial Neural Networks for In-field Recognition of Saffron Flower.** *Iran Agricultural Research*, Vol. 33, No. 1, 2014
- KOSCHAN, A.; ABIDI, M. **Digital Color Image Processing.** *Image Processing*, p. 375 pages, 2008.
- NEGBI, M. 1999. **Saffron cultivation: past, present and future prospects.** In: Negbi, M. (ed.), *Saffron, Crocus sativus L.* Harwood Academic Publishers, Australia, pp. 1–18.

OH, S. W.; KIM, S. J. **Approaching the computational color constancy as a classification problem through deep learning**. Pattern Recognition, Elsevier, v. 61, p. 405–416, 2017. ISSN 00313203.

OTSU, N. A **thresholding selection method from gray-level histogram**. IEEE Transactions on Systems, Man and Cybernetics, v. 9, n. 1, p. 62–66, 1979.

PEREZ, A. J. et al. **Colour and shape analysis techniques for weed detection in cereal fields**. Computers and Electronics in Agriculture, v. 25, n. 3, p. 197–212, 2000. ISSN 01681699.

PERESSINI C. I. **Análise experimental de algoritmos de constância de cor e segmentação para detecção de mudas de plantas**. USP – São Carlos 2018.

RATNASINGAM, S.; COLLINS, S. **Study of the photodetector characteristics of a camera for color constancy in natural scenes**. Journal of the Optical Society of America. A, Optics, image science, and vision, v. 27, n. 2, p. 286–294, 2010. ISSN 1084-7529.

RATNASINGAM S.; MCGINNITY T. M., **Chromaticity Space for Illuminant Invariant Recognition**, in IEEE Transactions on Image Processing, vol. 21, no. 8, pp. 3612-3623, Aug. 2012, doi: 10.1109/TIP.2012.2193135.

RASMUSSEN, J.; NTAKOS, G.; NIELSEN, J.; SVENSGAARD, J.; POULSEN, R.N.; CHRISTENSEN, S. **Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots?** Eur. J. Agron. 2016, 74, 75–92.

TANG, L.; TIAN, L.; STEWARD, B. L. **Color image segmentation with genetic algorithm for in-field weed sensing**. Agricultural and Biosystems Engineering, v. 43, n. 4, p.1019–1027, 2000. ISSN 00012351.

TAO CHENG et al. **Evaluation of RGB, Color-Infrared and Multispectral Images Acquired from Unmanned Aerial Systems for the Estimation of Nitrogen Accumulation in Rice**. Remote sensing. May 2018.

TIAN, L. F.; SLAUGHTER, D. C. **Environmentally adaptive segmentation algorithm for outdoor image segmentation**. Computers and Electronics in Agriculture, v. 21, n. 3, p. 153–168, 1998. ISSN 01681699.

TIAN-HUAI D. e XIN QU. **A Fast Feature Extraction Algorithm for Detection of Foreign Fiber in Lint Cotton within a Complex Background**. Acta Automatica Sinica, Vol 36, No.

6, June 2010.

TUCKER, C.J. **Red and photographic infrared linear combinations for monitoring vegetation.** Remote Sens. Environ. 1979, 8, 127–150.

VIBHUTE A. and BODHE S. K. **Applications of Image Processing in Agriculture: A Survey.** International Journal of Computer Applications (0975 – 8887) Volume 52– No.2, August 2012.

WOEBBECKE, D. et al. **Color indices for weed identification under various soil, residue, and lighting conditions.** Transactions of the ASAE, v. 38, n. 1, p. 259–269, 1995. ISSN0001-2351.