**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

Ivan Carlos Perissini

**Análise experimental de algoritmos de constância de cor
e segmentação para detecção de mudas de plantas**

São Carlos

2018

Ivan Carlos Perissini

**Análise experimental de algoritmos de constância de cor
e segmentação para detecção de mudas de plantas**

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, para obtenção do título de Mestre em Ciências - Programa de Pós-Graduação em Engenharia Mecânica.

Área de concentração: Dinâmica das Máquinas e Sistemas

Orientador: Prof. Dr. Glauco Augusto de Paula Caurin

VERSÃO CORRIGIDA

**São Carlos
2018**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

C446a Carlos Perissini, Ivan
Análise experimental de algoritmos de constância de
cor e segmentação para detecção de mudas de plantas /
Ivan Carlos Perissini; orientador Glauco Augusto de
Paula Caurin. São Carlos, 2018.

Dissertação (Mestrado) - Programa de Pós-Graduação
em Engenharia Mecânica e Área de Concentração em
Dinâmica das Máquinas e Sistemas -- Escola de
Engenharia de São Carlos da Universidade de São Paulo,
2018.

1. Detecção de mudas. 2. Segmentação por cor. 3.
Constância de cor. 4. Invariância luminosa. 5.
Agricultura de precisão. 6. Processamento de imagens.
I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **IVAN CARLOS PERISSINI**.

Título da dissertação: "Análise experimental de algoritmos de invariância luminosa e segmentação para detecção de mudas e plantas".

Data da defesa: 02/03/2018.

Comissão Julgadora:

Resultado:

Prof. Titular **Glauco Augusto de Paula Caurin**
(Orientador)
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Marcelo Andrade da Costa Vieira**
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Edilson Reis Rodrigues Kato**
(Universidade Federal de São Carlos/UFSCar)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Mecânica:
Prof. Associado **Gherhardt Ribatski**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

AGRADECIMENTOS

Agradeço a todos os docentes e funcionários da Escola de Engenharia de São Carlos que contribuíram para minha formação acadêmica, profissional e pessoal desde meu ingresso a Universidade. Em especial, agradeço a meu orientador, Prof. Dr. Glauco Augusto de Paula Caurin, que teve contribuição impar nesta jornada de longos anos dentro e fora da Instituição, sua confiança e suporte possibilitaram a concretização deste trabalho.

A Carmem, minha maior parceira, a certeza de que você estaria do meu lado ao longo de qualquer caminho me deram força e ainda dão para que eu continue em frente sem preocupações. Enquanto estivermos juntos nossa jornada sempre será bela. Agradeço a todo amor e apoio.

A meus pais, Rosemeire Cristina Ascencio Perissini e Carlos Roberto Perissini; e meu irmão Guilherme Perissini, cujo apoio e suporte foram incondicionais e essenciais não só para a conclusão do estudo, como para minha estabilidade moral e emocional ao longo deste processo. A esta família eu tenho minha eterna gratidão, pelos ensinamentos, confiança e carinho.

Aos meu colegas e amigos que trabalharam comigo na empresa Whirlpool e que compartilharam momentos e vivências enriquecedoras, nem sempre fáceis, mas de grande amadurecimento profissional e pessoal; além das experiências e aprendizados suas palavras de apoio e incentivo me ajudaram a tomar importantes decisões de vida. Em especial agradeço aos meus amigos Daniel Ferreira, Fabio Diório, Fabio Silva e Luiz Castilho vocês me desafiaram a sair do comodismo e buscar novos propósitos.

Aos integrantes dos grupos do laboratório de reabilitação e manipulação robótica o qual fui muito bem recebido e que no curto espaço de tempo juntos já demonstraram um grande coleguismo com disposição constante a ajudar com conhecimento e apoio moral.

Aos meus antigos e ainda atuais amigos que acompanharam e suportaram este meu percurso e proveram momentos de distração e conforto tão essenciais para o decorrer do trabalho.

E por fim, agradeço ao CAPES e ao Programa de Pós-Graduação da Engenharia Mecânica, pelo apoio e subsídios financeiros necessários a concretização e divulgação científica deste trabalho.

*“É melhor tentar e falhar, que preocupar-se e ver a vida passar.
É melhor tentar, ainda que em vão que sentar-se, fazendo nada até o final.
Prefiro caminhar na chuva, que em dias frios em casa me esconder.
Prefiro ser feliz embora "louco", que em conformidade viver.”*
Martin luther king

RESUMO

PERISSINI, I. C. **Análise experimental de algoritmos de constância de cor e segmentação para detecção de mudas de plantas.** 2018. 148p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

O uso da visão computacional vem ganhando espaço no contexto agrícola, especialmente com a evolução do conceito da agricultura de precisão. 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 neste trabalho uma análise da literatura e uma série de investidas experimentais de técnicas de processamento de imagens, para buscar melhores relações entre custo computacional e desempenho da detecção de mudas de plantas, visando atingir operações em tempo real com o uso de hardwares comuns e de baixo custo. Para tanto o trabalho investiga a composição de estratégias de segmentação a partir de diferentes espaços de cor e métodos de constância de cor, de forma a reduzir a variação luminosa, uma das maiores fontes de instabilidade nas aplicações de visão na agricultura. Os experimentos propostos foram divididos em duas fases; na primeira o sistema de medidas foi avaliado, definindo as métricas e condições experimentais adequadas para a segunda fase, composta de uma sequência de experimentos comparativos entre estratégias de segmentação sob diferentes condições de iluminação. Os resultados mostraram que as soluções são muito dependentes das condições da cena e uma série de alternativas promissoras de segmentação foram obtidas. Sua elegibilidade, porém, depende de considerações sobre a disponibilidade computacional e contexto de aplicação.

Palavras-chave: Detecção de plantas. Processamento de imagens. Segmentação por cor. Invariância luminosa. Agricultura de precisão.

ABSTRACT

PERISSINI, I. C. **Experimental analysis of color constancy and segmentation algorithms for plant seedlings detection.** 2018. 148p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

The use of computer vision has been gaining ground in the agricultural context, especially with the evolution of the concept of precision agriculture. Applications such as irrigation, fertilization and pest control are just some of the scenarios that this technology can be used. However, the demand for accessible and efficient systems together with the variations and visual noise from an external environment presents challenges to these processes. It was proposed in this study an analysis of the literature and a series of experimental investigations of image processing techniques, to search for better relations between computational cost and performance in the detection of seedlings, aiming to achieve real time operations with the use of common and low cost hardware. For this, the work investigates the composition of segmentation strategies from different color spaces and color constancy methods, in order to combat light variation, one of the major sources of instability in agricultural vision applications. The proposed experiments were divided into two phases; in the first the measurement system was evaluated, defining the metrics and suitable conditions for the experiments at second phase, composed of a sequence of comparative experiments of segmentation strategies under different lighting conditions. The results showed that the solutions are very dependent on the conditions of the scene and a series of promising segmentation alternatives were obtained. Their eligibility, however, depends on considerations about the computational availability and context of the application.

Keywords: Plant detection. Seedlings detection. Image processing. Color segmentation. Invariant Illuminant . Precision agriculture.

LISTA DE ILUSTRAÇÕES

Figura 1 – Modelo simples de um sensor de imagem. Figura adaptada de Gonzalez, Woods et al. (1992)	34
Figura 2 – Funcionamento do sensoriamento matricial de imagens.Figura adaptada de Gonzalez, Woods et al. (1992)	34
Figura 3 – Representação matricial de uma imagem.Figura adaptada de Gonzalez, Woods et al. (1992)	36
Figura 4 – Imagem original à esquerda e binarizada à direita. Figura reproduzida de Gonzalez, Woods et al. (1992)	37
Figura 5 – A luz que atinge a superfície é refletida para a câmera onde é amostrada nos sensores vermelho, verde e azul. (Figura adaptada de Lukac e Plataniotis (2007))	40
Figura 6 – Representação circular de matiz e saturação. Figura adaptada de Gonzalez, Woods et al. (1992)	44
Figura 7 – Aplicação do espaço de cor invariante à iluminação. (Figura reproduzida de Maddern, Stewart e Newman (2014))	51
Figura 8 – Aplicação do invariante para auxiliar na classificação de elementos urbanos (Figura reproduzida de Upcroft et al. (2014))	51
Figura 9 – Mudas de planta de soja, (a,b,c) imagens originais; (d,e,f) <i>excess green</i> (ExG); (g,h,i) <i>excess red</i> (ExR). (Figura reproduzida Meyer e Neto (2008).)	53
Figura 10 – Os quadrados A e B da imagem possuem exatamente o mesmo tom de cinza, mas a intensidade dos arredores de B o associa a cor clara. Edward H Adelson	57
Figura 11 – Topo: Imagem original. Esquerda abaixo: Resultado da MSRCR. Direita abaixo: Resultado da MSRCP. Figura reproduzida de Petro, Sbert e Morel (2014)	61
Figura 12 – Representação gráfica e tabela de um experimento fatorial com 3 fatores (MONTGOMERY, 2012).	65
Figura 13 – Dispositivos de captura, respectivamente a Webcam Logitech c615 e Raspicam rev 1.3.	68
Figura 14 – Raspberrypi 3 modelo B.	69
Figura 15 – Mudas de Morango, Hortelã e Manjeriçao respectivamente.	71
Figura 16 – Mudas de Soja e Milho respectivamente, em solo com detritos.	71
Figura 17 – Utilização da referência na condição de tempo aberto e nublado respectivamente.	72
Figura 18 – Esquema do sistema de captura utilizado nos experimentos.	76

Figura 19 – Fluxograma genérico do fluxo de dados da captura até a obtenção dos resultados para os 5 experimentos da campanha experimental, com destaque aos softwares utilizados.	77
Figura 20 – Resumo das etapas, objetivos e saídas dos experimentos da campanha experimental.	77
Figura 21 – Demonstrativo das abordagens de constância de cor	87
Figura 22 – <i>Variability Chart</i> dos tempos de processamento em milissegundos	89
Figura 23 – <i>Variability Chart</i> dos tempos de processamento normalizados	90
Figura 24 – <i>Variability Chart</i> do Raspberry Pi para os tempos de processamento (ms)	92
Figura 25 – <i>Variability Chart</i> do erro total de segmentação (%)	93
Figura 26 – Exemplo de variações de segmentação entre capturas consecutivas . . .	94
Figura 27 – <i>Variability Chart</i> do erro total de segmentação (%) para as abordagens baseadas em cor	94
Figura 28 – <i>Variability Chart</i> do tempo de processamento(ms) para o experimento 2	97
Figura 29 – <i>Variability Chart</i> do F-score para análise de desempenho de segmentação	98
Figura 30 – Tempo de processamento(ms) para o experimento 3 agrupado por abordagem	101
Figura 31 – F-score(%) do experimento 3 agrupado por abordagem	103
Figura 32 – Variability chart do F-score(%) para abordagem HSV(Intervalo)	106
Figura 33 – Variability chart do F-score(%) para abordagem HSV(H)	106
Figura 34 – Variability chart do F-score(%) para abordagem CrCb(Cg)	107
Figura 35 – Variability chart do F-score(%) para abordagem <i>Excess Green</i> em RGB	107
Figura 36 – Variability chart do F-score(%) para abordagem YCrCb(Cr+Cb) . . .	108
Figura 37 – Variability chart do F-score(%) para abordagem <i>Excess green</i> em CrCbCg	108
Figura 38 – Comparativo do F-score(%) entre a abordagem Cg em verde e a u^*-v^* em azul.	109
Figura 39 – Resultado do F-score(%) com a média das abordagens.	109
Figura 40 – Gráfico de Pareto dos efeitos pela média das abordagens.	111
Figura 41 – Gráfico de bolha das abordagens selecionadas para os próximos experimentos, destaque em azul para o método referência HSV(intervalo). . .	113
Figura 42 – Resultado de F-score(%) da média das abordagens agrupados por método de constância de cor.	115
Figura 43 – Comparação dos resultados de segmentação da abordagem Cr+Cb, para os diferentes parâmetros de percentil do método MSRCR (<i>Chromaticity preservation</i>).	118
Figura 44 – Imagem original no fim de tarde. Imagem resultante do Scale By Max com percentil 97%. Saída da segmentação pela abordagem Cg.	119
Figura 45 – Comparativo do F-score(%) entre a abordagem Cg sem pré-processamento em verde e Cg após <i>Scale By Max</i> em azul	120

Figura 46 – Gráfico de bolha dos 10 melhores resultados de F-score, com a adição do baseline, HSV(intervalo) sem invariância.	121
Figura 47 – Resultado de F-score(%) da média das abordagens agrupados por método de constância de cor sob condição crítica de iluminação.	124
Figura 48 – Cenas obtidas para a condição crítica de iluminação.	124
Figura 49 – Exemplo do resultado em iluminação crítica da Soja com sombra a partir do Retinex MSRCR (<i>Gain/Offset</i>).	126
Figura 50 – Exemplo do resultado em iluminação crítica da Soja com sombra a partir do Retinex MSR (<i>Chromaticity preservation 2</i>).	127
Figura 51 – Exemplo do resultado em iluminação crítica da Soja com sombra a partir do método <i>Scale By Max</i> com percentil de 97%	128
Figura 52 – Exemplo do resultado em iluminação crítica da Soja com sombra a partir do método da Referência	129
Figura 53 – Exemplo do resultado em iluminação crítica da Soja com sombra a partir do método <i>GrayWorld</i> para média	129
Figura 54 – Gráfico de bolha dos 10 melhores resultados de F-score em condição de iluminação crítica.	130

LISTA DE TABELAS

Tabela 1 – Vantagens e desvantagens de diferentes técnicas de medição para segmentação no contexto agrícola	32
Tabela 2 – Vantagens e desvantagens algoritmos de constância de cor	64
Tabela 3 – Especificações dos dispositivos de captura.	67
Tabela 4 – Especificações das unidades de processamento.	68
Tabela 5 – Condições do Experimento 1	78
Tabela 6 – Condições do Experimento 2	80
Tabela 7 – Relação das abordagens selecionadas para o comparativo	82
Tabela 8 – Condições do Experimento 3	83
Tabela 9 – Relação dos métodos de constância de cor selecionados	85
Tabela 10 – Condições do Experimento 5	86
Tabela 11 – Comparativo dos tempos de processamento (ms)	90
Tabela 12 – Aumento proporcional do processamento pelo uso das operações morfológicas	91
Tabela 13 – Acrescimo de tempo devido operação morfológica (ms)	91
Tabela 14 – Comparativo de resoluções e processamentos no tempo computacional (ms)	92
Tabela 15 – Comparativo do erro de segmentação(%)	95
Tabela 16 – Comparativo dos tempos médios de segmentação (ms)	97
Tabela 17 – Resultado F-score médio das abordagens sob diferente iluminações	100
Tabela 18 – Comparativo de tempo de processamento (ms) entre abordagens de segmentação	102
Tabela 19 – Resumo dos resultados de desempenho de segmentação	104
Tabela 20 – Resultado médio das abordagens por condição experimental,	110
Tabela 21 – Tabela de tempo de processamento (ms) para abordagens de constância de cor	114
Tabela 22 – Tabela comparativa dos métodos de constância de cor	116
Tabela 23 – Comparativo do desempenho médio de segmentação das estratégias por F-score	122
Tabela 24 – Tabela comparativa dos métodos de constância de cor sob condição crítica de iluminação	125
Tabela 25 – Resultados sem invariância das abordagens de segmentação sob condição crítica de iluminação	127
Tabela 26 – Comparativo das 10 melhores estratégias na condição crítica de iluminação	130
Tabela 27 – Comparativo das 10 melhores estratégias em geral sem restrição de tempo	134

Tabela 28 – Comparativo das 10 melhores resultados para condições normais de iluminação com restrições moderadas de tempo	135
Tabela 29 – Comparativo dos 10 melhores resultados para condições críticas de iluminação com restrições moderadas de tempo	135
Tabela 30 – Comparativo dos 10 melhores resultados gerais com restrições modera- das de tempo	136
Tabela 31 – Comparativo dos resultados com os 10 menores tempos de processamentos	137
Tabela 32 – Recomendações de constância de cor e abordagem de segmentação para diferentes condições de aplicação	138

LISTA DE ABREVIATURAS E SIGLAS

ExG	<i>Excess Green</i>
ExR	<i>Excess Red</i>
NDI	<i>Normalized vegetation index</i>
SSR	<i>Single-Scale Retinex</i>
MSR	<i>Mutliscale Retinex</i>
MSRCR	<i>Multiscales Retinex with color Restoration</i>
MSRCP	<i>MSR with chromaticity preservation</i>
DOE	<i>Design of Experiments</i>
Rpi	Raspiberry Pi
PC	Computador Pessoal
WM	Wolfram Mathematica
OpenCV	<i>Open Source Computer Vision</i>
VNC	<i>Virtual Network Computing</i>

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Contextualização	23
1.2	Objetivos	26
1.2.1	Objetivo Geral	26
1.2.2	Objetivo Específico	26
1.2.3	Estrutura do texto	26
2	CONSIDERAÇÕES TEÓRICAS	29
2.1	Deteccção de mudas de plantas	29
2.2	Processamento de imagens coloridas	33
2.2.1	Processamento de imagens coloridas	33
2.2.2	Segmentação	36
2.2.3	Operações morfológicas	38
2.3	Constância de cor	39
2.4	Abordagens de segmentação de cor	41
2.4.1	Modelo RGB	42
2.4.2	Modelo HSV	43
2.4.3	RGB normalizado (rgb)	44
2.4.4	XYZ	45
2.4.5	$L^*a^*b^*$ e $L^*u^*v^*$	45
2.4.6	YCrCb	46
2.4.7	Espaço de cor I_1, I_2, I_3	47
2.4.8	Espaço de cor I_1, I_2, I_3	48
2.4.9	Espaço de cor I, V_1, V_2	48
2.4.10	Espaço de cor invariante à iluminação	49
2.4.11	Índices de vegetação	52
2.5	Abordagens de Constância de Cor	54
2.5.1	Abordagem por referência	54
2.5.2	Gray World e Scale by Max	55
2.5.3	Retinex	56
2.5.4	Mapeamento Gamut	60
2.5.5	Abordagens estatísticas	62
2.5.6	Aprendizagem de máquina	62
2.5.7	Comparativo dos métodos	63
2.6	Projeto de experimentos (<i>Design of experiments</i>)	65

3	MATERIAIS E MÉTODOS	67
3.1	Hardware e software	67
3.2	Infraestrutura	69
3.3	Métricas	72
3.3.1	Métricas de desempenho de detecção	72
3.3.2	Métricas de desempenho computacional	74
3.4	Análise de resultados	75
3.5	Sistema de aquisição	75
3.6	Campanha Experimental	77
3.6.1	Experimento 1 - Análise inicial do sistema de medidas	78
3.6.2	Experimento 2 - Análise complementar do sistema de medidas	79
3.6.3	Experimento 3 - Comparativo das abordagens de segmentação	81
3.6.4	Experimento 4 - Avaliação das abordagens de constância de cor	84
3.6.5	Experimento 5 - Comparativo das abordagens em condição crítica de iluminação	85
4	RESULTADOS	89
4.1	Resultados do experimento 1	89
4.2	Resultados do experimento 2	96
4.3	Resultados do experimento 3	101
4.4	Resultados do experimento 4	114
4.5	Resultados do experimento 5	123
4.6	Avaliações Práticas	132
4.6.1	Melhores resultados para aplicações sem restrição de tempo	133
4.6.2	Melhores resultados para aplicações com restrições moderadas de tempo	134
4.6.3	Melhores resultados para aplicações com altas restrições de tempo	137
5	CONSIDERAÇÕES FINAIS	139
5.1	Discussão	139
5.2	Propostas para trabalhos futuros	142
	REFERÊNCIAS	143

1 INTRODUÇÃO

1.1 Contextualização

A demanda global pelos produtos agrícolas está crescendo rapidamente, de forma que vivemos hoje o desafio de aumentar a produção em resposta à demanda da crescente população e PIB mundial. Para tal, desmatar nova áreas e intensificar as produções agrícolas surgem naturalmente como primeira alternativa. Entretanto, estas ações intensificam também os impactos ambientais (TILMAN et al., 2011), que já caracterizam uma preocupação global, sendo vital a busca por um desenvolvimento sustentável para a agricultura. O grande desafio reside em aumentar a produção, diminuindo a degradação e esgotamento das áreas de plantio. Neste contexto a agricultura de precisão está cada vez mais presente como uma das grandes alternativas para melhorar a eficiência na aplicação de insumos, garantindo maior controle dos nutrientes, pestes e consequentemente melhor manejo das áreas produtivas (MATSON et al., 1997).

Agricultura de precisão foi definida pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) em 2011 como:

“Sistema de gerenciamento agrícola baseado na variação espacial de propriedades do solo e das plantas encontradas nas lavouras e visa à otimização do lucro, sustentabilidade e proteção do ambiente” (BRASIL, 2011).

Segundo Bernardi et al. (2014), é importante apontar que os ganhos além de ambientais são também econômicos e estes podem ser obtidos principalmente de duas formas: eliminando-se o erro antrópico, isto é, com o auxílio da tecnologia e seleção dos equipamentos corretos, as influências e erros dos operadores são reduzidos, melhorando-se o retorno econômico; em segundo lugar, têm-se os erros naturais, comumente associados às diferenças e variações próprias da produção ao longo da plantação. Encontrar e aplicar a relação ótima de insumos reduz os gastos associados ao próprio insumo e melhora a eficiência da produção como um todo.

No universo do conhecimento referente à agricultura de precisão e de suas tecnologias de aplicação, a visão computacional está emergindo como um promissor método de aquisição de informações e automatização de processos (STEWART et al., 2004). Isto porque tal recurso é capaz de avaliar automaticamente diversas condições de plantas diferentes a uma alta frequência espacial, como por exemplo reconhecer tamanho, forma, cor, textura e diversos outros aspectos da cena sendo capturada (MCCARTHY; HANCOCK; RAINE, 2010). As informações obtidas são capazes de extrapolar os domínios dos objetos na região visível, fazendo uso de sistemas de visão ultravioleta (UV), infravermelho próximo (NIR), infravermelho (IF) e outros. Tais abordagens possibilitam o fornecimento de dados

adicionais importantes, como maturidade da planta, qualidade, doença e estresse ([CHEN; CHAO; KIM, 2002](#)).

Desta forma, aplicações desta tecnologia abrangem desde o reconhecimento de espécies, estimadores de crescimento, detecção de doenças, identificação de linhas de cultura, sistemas de irrigações, fertilizações e controle de pestes automatizadas, até o desenvolvimento de modelos de estimativas de rendimento da produção ([KATAOKA et al., 2003](#); [CAMARGO; SMITH, 2009](#); [MCCARTHY; HANCOCK; RAINE, 2010](#); [JEON; TIAN; ZHU, 2011](#); [GARCÍA-SANTILLÁN et al., 2017](#)). Avanços nas tecnologias de visão computacional estão se consolidando como uma importante solução para a indústria agrícola, garantindo operações de tempo real de baixo custo com elevada precisão e robustez ([CHEN; CHAO; KIM, 2002](#)).

Grande parte das aplicações de visão computacional fazem uso de abordagens de reconhecimento de objetos em ao menos uma das etapas do processamento das imagens, de forma a identificar os elementos para as análises subsequentes bem como capturar informações espaciais e outras peculiaridades do ambiente. O reconhecimento é obtido através da segmentação da imagem, isto é, associações e subdivisões são realizadas na imagem de acordo com regiões de características similares. Tais regiões, após serem interpretadas e identificadas, garantem a detecção dos objetos. Esta etapa, apesar de constituir-se talvez como a mais difícil para o processamento, é de elevada importância, e sua qualidade impacta diretamente nos resultados ([TANG; TIAN; STEWARD, 2000](#)).

Uma abordagem muito utilizada para a segmentação da imagem é a agregação de seus elementos a partir de suas similaridades de cor, ou seja, detecção por cor. No contexto agrícola sua aplicação é grandemente explorada para identificação de pragas e mudas em contraste com solo, bem como para detecção de frutos devido às suas cores características. A facilidade de acesso a câmeras com aquisição de imagens coloridas, aliada ao fato destas fornecerem muito mais informações a respeito do ambiente do que as câmeras monocromáticas, e ainda a relativa facilidade da abordagem por cor em relação a abordagens de segmentação por forma e textura, tendem a favorecer a aplicação destas estratégias ([TIAN; SLAUGHTER, 1998](#); [EL-FAKI; ZHANG; PETERSON, 2000](#); [HAMUDA; GLAVIN; JONES, 2016](#)).

Entretanto tal estratégia de segmentação por cor ainda possui inúmeros desafios, principalmente quando sua utilização é feita em ambientes externos, devido às dificuldades de se trabalhar em um ambiente não controlado. Em especial as influências da iluminação e a presença de sombras são as principais fontes de variações nas propriedades visíveis do objeto, tornando a detecção e identificação muito mais inconstantes e difíceis, especialmente nos aspectos de cor. Para suplantarmos estes desafios, técnicas de processamento de imagens e algoritmos podem ser desenvolvidas e aprimoradas, visando eliminar os ruídos associados às condições ambiente e extrair apenas as informações úteis da imagem ([TIAN;](#)

SLAUGHTER, 1998; HERNÁNDEZ-HERNÁNDEZ et al., 2016; HAMUDA; GLAVIN; JONES, 2016).

Abordagens para eliminar os efeitos da fonte de luz nas cores do objeto são conhecidas como métodos de constância de cor. As propostas para solucionar as problemáticas descritas são as mais variadas, partindo de pressupostos sobre a cena, fonte de iluminação, dispositivo de captura ou de combinações dos mesmos (RATNASINGAM; MCGINNITY, 2012). Entretanto apesar da grande quantidade de algoritmos propostos para constância de cor, nenhuma solução única foi identificada, as possibilidades de aplicações e de condições ambientais são tão amplas e diversas que impedem a obtenção de uma solução universal, de forma que as abordagens estão muito mais orientadas às suas aplicações e à problemas particulares (AGARWAL et al., 2006; GIJSENIJ; GEVERS; Van De Weijer, 2011). Recentes avanços tem mostrado resultados promissores com o uso de redes neurais convolucionais e *deep learning* (BIANCO; CUSANO; SCHETTINI, 2015; LOU et al., 2015; OH; KIM, 2017), mas sua implementação requer dados de treinamento e custos computacionais relativamente altos, restringindo sua aplicação.

O ambiente agrícola, por se tratar de um universo mais restrito de condições e aplicações, possui algumas abordagens específicas para o tratamento das variações de luz. Diversos espaços e índices de cor foram desenvolvidos e utilizados para imagens coloridas para segmentação de plantas, partindo de condições particulares como a diferenciação natural que usualmente ocorre do verde das plantas com a terra. Entretanto, novamente não se observa o destaque de uma única abordagem na tratativa do problema, sendo que as condições dos testes são muito particulares, dificultando a comparação entre os métodos e a documentação de sua acurácia não é clara (MEYER, 2011).

Apesar das diversas abordagens de índices de cor, nota-se uma carência da utilização de algoritmos mais amplos e tradicionais de constância luminosa no meio agrícola, seja para própria segmentação ou com etapa de pré-processamento para as imagens. Outro aspecto pouco explorado é a avaliação dos tempos de processamento e custo computacional dos métodos, da mesma forma que os hardwares utilizados são poucos discutidos e o processamento em unidades embarcadas é raramente realizado, dificultando a análise do desempenho e da viabilidade dos sistemas de visão como um todo.

Frente ao que foi aqui apresentado, é possível observar que o caminho para o desenvolvimento tecnológico na agricultura é muito promissor, visto que além dos desafios de redução dos impactos ambientais, a maior parte da produção global possui plantios com capacidade produtiva bem abaixo de seu potencial (TILMAN et al., 2011). Igualmente, pôde-se evidenciar que aplicações de algoritmos de constância de cor são interessantes alternativas para aplicação de sistemas de visão em ambientes externos e agrícolas. E que apesar da diversa gama de algoritmos para constância de cor, as soluções são muito particulares as aplicações e as condições de operação do sistema de visão. Desenvolvimentos

para explorar estas frentes são necessários para garantir um meio ambiente mais sustentável e uma distribuição global mais igualitária de alimentos.

1.2 Objetivos

1.2.1 Objetivo Geral

O presente estudo propõe avaliar, comparar e determinar alternativas de software que apresentem bom desempenho de detecção e baixo custo computacional para a operação de segmentação de plantas em sistemas de visão computacional. Em aspectos práticos, objetiva viabilizar hardwares de baixo custo e acessíveis a serem utilizados com eficiência em sistemas embarcados de tempo real para detecção de mudas no meio agrícola.

1.2.2 Objetivo Específico

O trabalho em questão propõe realizar uma análise da literatura de técnicas de segmentação de objetos e contextualizá-las ao ambiente agrícola, e em sequência através de experimentos planejados, avaliar o desempenho de diversas abordagens e suas interações com diferentes hardwares e condições de aplicação.

Pretende-se desta forma identificar as configurações que mais se destacam para atender ao problema de detecção e localização espacial de mudas de plantas em tempo real, em um ambiente externo genérico e tipicamente agrícola. Por melhor abordagem para detecção e localização entende-se por:

- Maior exatidão na detecção das mudas de planta
- Menor ocorrência de falsas detecções
- Melhor acurácia e precisão em relação ao centro do objeto
- Menor custo computacional
- Menor latência
- Menor complexidade operacional
- Melhor aplicabilidade e facilidade de acesso

1.2.3 Estrutura do texto

Esta dissertação está dividida da seguinte forma:

- Capítulo 2 – Apresenta uma revisão dos conceitos teóricos utilizados no presente estudo, além de explicar sobre a metodologia da abordagem experimental utilizada, o projeto de experimentos (Design of Experiments - DOE), compreendendo assim as informações para o entendimento básico da dissertação.

- Capítulo 3 – Neste capítulo serão detalhados os materiais e métodos a serem utilizados nas análises e campanhas experimentais, assim como o descritivo das estratégias de amostragens e estrutura dos experimentos.
- Capítulo 4 – Descritivo da campanha experimental, com as análises, discussões e sequencia de descobertas, assim como uma análise final prática dos resultados obtidos.
- Capítulo 5 – Considerações finais com as conclusões, sugestões e próximos passos para o estudo

2 CONSIDERAÇÕES TEÓRICAS

Como previamente discutido, o trabalho em questão pretende avaliar analiticamente e empiricamente os métodos mais adequados para detecção de mudas em ambiente externo agrícola. Para tanto as bases teóricas de processamento de imagens associados às abordagens testadas serão aqui discutidas de forma a propiciar o entendimento necessário para o acompanhamento do estudo.

Inicialmente este capítulo buscará explorar o entendimento do problema de detecção proposto e discorrer sobre as práticas e realidades atuais neste contexto. Em sequência, tem-se uma breve introdução e explanação dos termos relevantes para o estudo em processamento de imagens, seguido pela literatura atual sobre as abordagens de constância de cor e invariância luminosa que serão avaliadas no projeto. Por fim o capítulo abordará conceitos de projetos de experimentos, que irão orientar a estratégia amostral, o formato e as análises do experimento.

2.1 Detecção de mudas de plantas

A detecção de mudas de plantas é um problema constante no universo da agricultura de precisão. A obtenção de informações associadas às plantas possibilita diversas e lucrativas aplicações, que vão desde de algoritmos de classificação de mudas, análises de qualidade e estimadores de produção até automatizações de processos como o de irrigação de mudas jovens e eliminação de pragas, como plantas daninhas.

Entretanto, tais processos automatizados ainda não estão dominados e suficientemente difundidos, sendo que o método manual ainda é o mais utilizado para garantir a identificação e aplicações locais dos insumos. Este se mostra altamente oneroso e dependente de mão de obra. Tal realidade estimula ainda mais o estudo e desenvolvimento de tecnologias para sensoriamento e atuação em tempo real destes processos, pois garantiria não somente a redução de mão de obra, como também um maior controle do processo e uso otimizado dos insumos (BERNARDI et al., 2014).

Uma tecnologia que se tem mostrado promissora para esta abordagem é a visão computacional. Sua alta resolução, consistência, capacidade de capturar informações espaciais e as mais diversas informações ópticas aliadas a um custo cada vez mais acessível são alguns dos principais motivos (MCCARTHY; HANCOCK; RAINE, 2010; CHEN; CHAO; KIM, 2002; EL-FAKI; ZHANG; PETERSON, 2000; MEYER, 2011).

Para detecção de mudas a partir de sistemas de visão, a etapa de segmentação da imagem é crítica e essencial. Para realizar este agrupamento das características associadas à planta em contraste com o terreno e demais resíduos, diversas abordagens são utilizadas,

sejam elas de software ou hardware. Algumas das principais serão descritas na sequência, assim como suas considerações para este trabalho:

- Segmentação por forma: baseia-se na detecção da planta por meio da identificação do formato das folhas. Esta abordagem, apesar de possivelmente ser menos sensível à iluminação que outros métodos, demanda maior processamento ([JIMENEZ; CERES; PONS, 2000](#)). Além disto, esta detecção possui diversos complicadores: em primeiro lugar existe muita diferença de folhas entre as espécies de plantas; além disso, algumas situações como diferença na orientação, sobreposição das folhas, variações da distância da câmera com o objeto, e efeitos da ação do vento dificultam muito esta abordagem, pois modificam a visão, foco e contornos das folhas ([EL-FAKI; ZHANG; PETERSON, 2000](#)).
- Segmentação por textura: esta abordagem faz uso da percepção de características da textura do objeto, como a regularidade, granulosidade, suavidade ou grosseria de uma superfície e demais perfis detectáveis na imagem ([GONZALEZ; WOODS et al., 1992](#)). Esta abordagem também possui aplicações de sucesso para identificar plantas, através de suas folhas; entretanto, requer imagens de alta resolução e, no contexto agrícola, está sujeita aos mesmos desafios e problemas da abordagem por forma, sendo geralmente um método de alto consumo computacional ([EL-FAKI; ZHANG; PETERSON, 2000](#); [MEYER, 2011](#)).
- Segmentação por intensidade luminosa: representa a abordagem mais simples em que, por meio de uma imagem monocromática (escala cinza), as plantas são destacadas do solo e de resíduos devido à diferença de intensidade luminosa entre eles. Nesta situação, a segmentação é feita através da determinação do valor de corte que separa estes dois grupos. Entretanto, apesar da simplicidade, este método em ambientes externos é pouco eficiente pois frequentemente a intensidade do objeto e do fundo estão sobrepostas, sendo altamente vulneráveis às condições e variações da iluminação ([TIAN; SLAUGHTER, 1998](#)). Algumas abordagens alternativas foram estudadas, como por exemplo, o uso de imagens monocromáticas com filtros de cor; porém, apesar de sucesso em ambientes laboratoriais, seu bom desempenho não foi constatado em ambientes externos ([CHAISATTAPAGON, 1995](#)).
- Segmentação por cor: talvez a mais intuitiva das segmentações, baseia-se nas diferenças de cor entre as plantas - geralmente caracterizadas pela cor verde e similares - em contraponto à cor do solo e demais resíduos - tipicamente marrons e cinzas. ([WOEBBECKE et al., 1995](#)). Esta abordagem em sistemas de visão é reconhecida como uma excelente, e por vezes negligenciada, fonte de informação ([CASADY et al., 1992](#) apud [EL-FAKI; ZHANG; PETERSON, 2000](#)). No contexto proposto, requer menos restrições sobre a posição da câmera, orientação e sobreposição das folhas que

as outras abordagens e fornece simultaneamente informações sobre três diferentes canais de cor, provendo grande vantagem sobre os sistemas monocromáticos (EL-FAKI; ZHANG; PETERSON, 2000). O sucesso desta abordagem já foi observado em algumas aplicações; entretanto, as condições de iluminação variáveis, tanto em direção como intensidade, e a oclusão e sombras influenciam diretamente na acurácia destes métodos. Algumas estratégias comumente exploradas nestas abordagens são a utilização de placas de fundo e/ou aparatos para criação de sombras aliadas à iluminação artificial. Estas auxiliam a reduzir os efeitos da iluminação e consequentemente a complexidade dos algoritmos de segmentação, mas adicionam elementos e restrições físicas ao projeto (MCCARTHY; HANCOCK; RAINE, 2010).

- Segmentação multiespectral: São métodos de segmentação que fazem uso de propriedades das plantas que não são visíveis para os humanos. Estas técnicas apesar de possuírem dificuldades específicas e não serem tão intuitivas, geralmente simplificam os algoritmos de detecção, pois partem de diferenciações naturais da planta com o solo. Além disto podem fornecer informações adicionais diferentes das abordagens convencionais. As técnicas desta abordagem vão desde sistemas de raio X, câmeras térmicas, filtros ópticos ajustáveis até sistemas infravermelhos. A Tabela 1, adaptada de Gowen et al. (2010), apresenta um comparativo entre o método óptico convencional e algumas técnicas multiespectrais. Existem diversos casos de sucesso nestas abordagens; entretanto, a grande restrição destes métodos é a dificuldade de acesso e o custo dos hardwares específicos para estas aplicações (MCCARTHY; HANCOCK; RAINE, 2010).
- Segmentação por infravermelho: como discutido no tópico acima, trata-se de um caso particular de segmentação multiespectral, que faz uso do princípio de que a planta possui maior refletância que o solo em comprimentos de onda no infravermelho próximo (KUMAR et al., 2002 apud MCCARTHY; HANCOCK; RAINE, 2010). Esta característica natural da vegetação facilita a distinção dos objetos, simplificando a complexidade do software e, consequentemente, o custo computacional. As dificuldades desta abordagem residem inicialmente na dissociação da imagem em relação à percepção visual humana, dificultando por vezes o entendimento e interpretações dos resultados; outra dificuldade é a dependência de hardware especiais ou de modificações de câmeras com a remoção dos filtros de infravermelho. A ampliação de alternativas de baixo custo nesta frente aumenta a sua atratividade, mas seu acesso ainda é mais restrito que câmeras coloridas convencionais (MCCARTHY; HANCOCK; RAINE, 2010). A Tabela 1 a seguir ilustra alguns dos principais tipos de métodos espectrais disponíveis.

Esta revisão trata algumas das abordagens de segmentação mais conceituadas e utilizadas no contexto agrícola. Vale a ressalva de que cada uma possui inúmeras

Tabela 1: Vantagens e desvantagens de diferentes técnicas de medição para segmentação no contexto agrícola

Técnica	Princípio	Vantagens	Desvantagens
Testagem visual	Óptico-mecânica	Baixo-custo Treinamento mínimo	Consumo de tempo Baixa resolução Repetitividade Alta taxa de erro
Testagem radiográfica	Radiação penetrante	Ausência de contato	Consumo de tempo Periculosidade
Ressonância magnética nuclear	Campo magnético	Rápido, podendo ser utilizada em testagens de rotina	Alto custo
Testagem ultrassônica	Sônico-Ultrassônico	Ausência de contato	Medida de único ponto Limitada pela impedância acústica
Imagens Térmicas	Medidas de temperatura e fluxo de calor	Ausência de contato Ausência de radiação nociva Alta portabilidade Imagens em tempo real	Requer treinamento Alto custo
Topografias de raio-x	Comprimento de onda de espectro eletro-magnético (<1nm)	Ausência de contato	Consumo de tempo Periculosidade Não aplicável a produtos em fluxo contínuo
Imagem hiperespectral	Espectroscopia	Informação multi-constituída Sensibilidade a componentes menores	Requer treinamento Alto custo

Fonte: [Gowen et al. \(2010\)](#) (tradução livre)

particularidades e variações que dependem das aplicações, do hardware utilizado e das demais condições que não podem ser cobertas pela profundidade proposta para a discussão deste trabalho.

Além disto, as aplicações de segmentação não se atêm apenas às divisões demonstradas nesta seção e comumente vemos abordagens que se valem de duas ou mais propriedades para identificar os objetos em estudo. Em diversos casos esta múltipla abordagem, bem

como o uso de algoritmos adaptativos e de etapas de pré-processamento para realce de características é recomendada e necessária para fornecer maior robustez e confiança nos resultados (TIAN; SLAUGHTER, 1998; MCCARTHY; HANCOCK; RAINE, 2010; MEYER, 2011).

A segmentação por cor se apresenta como uma promissora abordagem, com hardware de baixo custo, acessível e em constante evolução tecnológica, tanto para as câmeras coloridas na aquisição das imagens como para unidades embarcadas compatíveis para o processamento. Além disso, de forma geral esta abordagem se mostra mais intuitiva, flexível e menos complexa que os métodos baseados em forma e textura.

2.2 Processamento de imagens coloridas

O processamento de imagens pode ser entendido como qualquer operação ou conjunto de operações realizadas computacionalmente em uma imagem digital com o intuito de gerar outra imagem ou de extrair informações e/ou atributos da mesma. Este processo tem duas principais áreas de aplicações: aprimorar as informações de imagens para interpretação humana e processar dados para manipulação e uso de processos automatizados (GONZALEZ; WOODS et al., 1992).

O processamento de imagens coloridas trata-se apenas de uma condição particular de processamento, em que a imagem difere da convencional (monocromática) pela representação de seus valores de intensidade por valores tridimensionais na forma de vetores, adicionando as informações de cor na cena, além da informação espacial. Esta mudança de perspectiva adiciona muita informação à imagem, constituindo um bom método de descrição, garantindo frequentemente uma simplificação na identificação de objetos.

Os fundamentos teóricos de processamento de imagens e das cores em imagens digitais tratados neste tópico têm como constante referência o livro *Digital Image Processing*, de Gonzalez, Woods et al. (1992), considerado o principal livro didático sobre o assunto por mais de 30 anos. O conteúdo em questão é muito amplo, portanto os tópicos que seguem cobrem apenas o suficiente e relevante para o entendimento do estudo.

2.2.1 Processamento de imagens coloridas

Todo sistema de visão e técnicas de processamento de imagens possui como informação de entrada as imagens digitais. Estas, por sua vez, são resultados da digitalização de sinais elétricos produzido por conjuntos de sensores sensíveis às energias provenientes da cena à qual eles são expostos.

Cada unidade sensora é sensibilizada por um tipo de energia. Esta pode ser raio-X, infravermelho, ultrassom e, a mais comum e utilizada no caso do projeto, a luz visível. Sua unidade básica pode ser visualizada na representação da Figura 1.

Figura 1: Modelo simples de um sensor de imagem. Figura adaptada de [Gonzalez, Woods et al. \(1992\)](#)

As câmeras digitais são os hardwares que possibilitam a geração das imagens digitais convencionais, capturando o estímulo luminoso por meio de uma matriz de sensores ópticos, deste modo, vários pontos da imagem podem ser obtidos simultaneamente.

Um processo genérico de obtenção de uma imagem digital pode ser visualizado na Figura 2. Um objeto reflete a energia de uma fonte luminosa para um sistema de imagem. Este sistema coleta a energia e a foca em um plano de imagem que, no caso de câmeras digitais, é realizado por um jogo de lentes. Por fim, a matriz de sensores que é coincidente ao plano de imagens produz saídas de tensão proporcionais à excitação que cada sensor recebe. Estes valores, após serem digitalizados, geram a imagem digital do objeto.

Figura 2: Funcionamento do sensoriamento matricial de imagens. Figura adaptada de [Gonzalez, Woods et al. \(1992\)](#)

Uma imagem digital convencional (monocromática) é uma resposta proveniente de uma função bidimensional na forma $f(x, y)$, cujos pontos (x, y) estão associados a coordenadas no plano da imagem e o valor de f é um escalar positivo cujo significado físico está ligado à interação da fonte de luz com o objeto no ponto em questão, sendo denominado por valor de intensidade luminosa ou nível de cinza. Sua função $f(x, y)$ é caracterizada pela multiplicação de dois fatores:

- Iluminação, quantidade de luz incidente na cena, valores positivos.
- Refletância, quantidade de luz refletida pelos objetos na cena, variando de 0 a 1.

Sendo definida por:

$$f(x, y) = \text{iluminação} \cdot \text{refletância} = i(x, y) \cdot r(x, y) \quad (2.1)$$

A imagem em sua essência é uma função contínua tanto em relação às suas coordenadas x e y , quanto em relação à sua amplitude. Sua conversão para a forma digital, se dá pelo processo de discretização ou digitalização. Cada ponto digitalizado da matriz de sensores que contém um valor a ele associado é denominado pixel ou píxel, constituindo o elemento básico de uma imagem digital. Em termos práticos, quanto maior a quantidade de *pixels* para uma mesma imagem original, menos perceptível é a digitalização e, por consequência, melhor a qualidade da imagem digital.

A forma mais usual de representação de imagens digitais é a forma matricial, sendo que cada elemento da matriz representa um pixel. Os índices do elemento representam os indicadores da posição e sua amplitude é o indicador de intensidade do pixel. É usualmente convencionado que a origem da imagem se localiza no canto superior esquerdo, baseado no fato de que vários displays de imagens realizam a varredura desta partindo desse ponto. A Figura 3 demonstra esta representação de imagens.

No caso de imagens coloridas, a principal diferença na representação em relação à monocromática reside no fato de a mesma possuir um número superior de dimensões de intensidade para cada posição da imagem. Em outras palavras, equivale a dizer que cada pixel da imagem digital colorida é composto por um vetor, geralmente tridimensional, sendo cada dimensão responsável por caracterizar uma cor no seu respectivo modelo de cor.

Os principais modelos de cor utilizam três dimensões para representar as cores, sendo eles o conhecido RGB (*Red Green Blue*), amplamente utilizado em monitores, câmeras e displays, o CMYK (*Cyan Magenta Yellow Black*), presente em grande parte dos dispositivos de impressão, e o HSI (*Hue Saturation Intesity*), com uma abordagem

Figura 3: Representação matricial de uma imagem. Figura adaptada de [Gonzalez, Woods et al. \(1992\)](#)

matemática próxima à percepção de cor do ser humano. Estes e outros modelos de cor serão abordados com mais detalhe nos subtópicos seguintes.

2.2.2 Segmentação

Segmentação é uma importante etapa de processamento de imagens cujo processo consiste em dividir a imagem em regiões ou objetos de interesse. Desta forma consegue-se extrair atributos das imagens, obtendo informações numéricas dos objetos e da cena, garantindo a aplicabilidade de sistemas de visão como sensor para as mais diversas atividades automatizadas.

A precisão e desempenho do processo de segmentação influenciam os dados que serão tratados nas atividades subsequentes de processamento e podem prejudicar completamente a eficiência de todo o sistema. A maior parte dos algoritmos de segmentação são baseados em dois princípios básicos: as discontinuidades; e as similaridades das informações da imagem. Na primeira abordagem a divisão da imagem ocorre em função das mudanças abruptas das imagens, como bordas, grande variação de intensidade e níveis muito distintos de cor. Já a segunda abordagem baseia-se na união e determinação de regiões em função de sua similaridade de acordo com um conjunto pré-definido de critérios.

O método mais intuitivo e simples nas aplicações de segmentação é o da limiarização (*thresholding*). Sua aplicação, além de ser bastante eficaz, traz também baixo custo computacional; consiste na simples implementação de um ou mais valores de cortes dos

quais os conjuntos de dados dentro dos limites é destacado dos demais, separando a imagem em diferentes regiões dominantes. Em geral atribui-se para sua representação o preto para o fundo, e o branco para o objeto de interesse. Este processo é também conhecido como binarização e pode ser visualizado na Figura 4.

Figura 4: Imagem original à esquerda e binarizada à direita. Figura reproduzida de [Gonzalez, Woods et al. \(1992\)](#)

A limiarização é uma abordagem pixel a pixel que pode ser aplicada de diversas formas, e não se restringe às imagens em escala cinza podendo seus conceitos serem estendidos a imagens com diversos canais e a diferentes espaços de cor. Algumas das características e abordagens mais pertinentes serão discutidas a seguir:

- Limiar global – Característica do limiar que define que seu valor é constante e será aplicado a toda a imagem.
- Limiar local ou variável – Característica do limiar que define que o mesmo varia seu valor ao longo da imagem em função dos valores vizinhos ao pixel observado.
- Limiar simples – Atribuição de apenas um valor de corte para a imagem.
- Múltiplos Limiares – Utilização de um conjunto de condições e múltiplos valores de corte de forma a selecionar características dentro de intervalos, ou para gerar múltiplos níveis de segmentação.
- Método de Otsu – Técnica para determinar o limiar ótimo de uma imagem. Parte da suposição de que as distribuições de intensidades da imagem são funções Gaussianas e calcula desta forma o valor de corte que minimiza a variância intraclases, medida comumente usada em análise discriminante. O método de Otsu é uma abordagem bem-conceituada que requer apenas os valores do histograma da imagem, isto é, uma representação da quantidade de píxeis em cada nível de intensidade ([OTSU, 1979](#)).

Apesar dos cálculos não serem triviais, isto configura para o processamento um vetor de fácil obtenção.

- Demais Métodos: Métodos adicionais de aplicação envolvem abordagens iterativas para limiar global, segmentação por descontinuidades nas imagens, limiar variável baseado nos valores dos píxeis da vizinhança, regiões de crescimento, segmentações morfológicas entre outras, apresentando maior complexidade e consequentemente maior custo computacional.

Como discutido, a partir da segmentação, diversos atributos da imagem podem ser adquiridos. Em aplicações agrícolas algumas das operações mais recorrentes consistem em realizar o rastreamento das mudas no ambiente agrícola, as informações mais relevantes estão assim associadas às características espaciais e geométricos do objeto. Entre elas podemos destacar:

- Área – Característica dimensional de um dado objeto obtida com a simples contagem do número de píxeis relevantes (valor = 1). A resposta da área é diretamente proporcional à proximidade do objeto à câmera e ao tamanho do objeto. Dentre as diversas aplicações, pode ser usado para discriminar múltiplos objetos ou evidenciar valores dimensionais do objeto fora de limites especificados.
- Centroide – Também chamado de centro de gravidade, é uma coordenada na imagem que representa centro geométrico do objeto de interesse. Seu valor é obtido pelo cálculo do valor médio das coordenadas (x, y) dos píxeis ativos do objeto em questão. Sua aplicação é altamente presente em sistemas de rastreamento de objetos pois fornece a localização espacial do objeto de maneira sucinta e de fácil processamento.

Nota-se que a eficácia na captura destes atributos e, consequentemente, o desempenho de sistemas com rastreamento, estão intimamente ligados aos algoritmos e abordagens de segmentação.

2.2.3 Operações morfológicas

A partir de imagens já segmentadas (binarizadas), alguns processamentos particulares conhecidos como operações morfológicas, baseados na forma do objeto e teorias de conjunto fornecem simples, mas poderosas ferramentas para auxiliar no processo de segmentação, melhorando a detecção do objeto ao remover imperfeições decorrentes de seu processo. Suas operações básicas são a erosão e dilatação, decorrentes de relações de conjuntos distintas, provenientes da translação de um elemento estruturante ao longo da imagem.

Na operação de dilatação o elemento estruturante é refletido em relação a sua origem e em seguida posicionado e deslizado na imagem, verificando a existência de qualquer possível intersecção com a imagem original, gerando uma nova imagem por meio da união dos conjuntos ao longo deste processo. A operação de erosão possui abordagem similar, mas seu elemento estruturante não é refletido, e a imagem resultante é formada pelo conjunto da intersecção dos conjuntos ao longo da translação. Para fins práticos a operação de dilatação expande as bordas da imagem, eliminando ruídos brancos internos a conjuntos pretos, reparando quebras e intrusões. Já a erosão contrai as bordas da imagem, eliminando ruídos pretos, além de dividir objetos e remover extrusões.

A partir destas operações básicas outras duas importantes operações morfológicas podem ser realizadas por meio de suas combinações. São elas: as operações de fechamento, proveniente de uma dilatação seguida de uma erosão; e abertura, com uma erosão seguida de uma dilatação. O fechamento é utilizado para suavizar contornos, eliminar pequenos buracos e lacunas e unir conjuntos. Já a abertura também suaviza os contornos da imagem mas, diferentemente, ele elimina extrusões, ruídos e separa conjuntos ligados por trechos estreitos. Estas operações morfológicas buscam manter as dimensões originais das estruturas principais enquanto corrigirem eventuais defeitos no processo de segmentação como a eliminação de ruídos na imagem.

2.3 Constância de cor

A geração de uma imagem digital é influenciada por diversos fatores físicos da cena, principalmente ao lidarmos com ambientes e iluminações com poucas ou nenhuma restrição, e com objetos brilhantes e de geometria complexa. Situações e aplicações reais de processamento estão constantemente submetidos a estes ruídos e complicadores, alterando os valores de brilho e cor da imagem, o que dificulta as operações de segmentação e consequentemente o rastreamento de objetos de interesse.

Os fenômenos mais comuns em situações práticas são: a ocorrência de destaques luminosos na imagem devido à presença de objetos com superfícies especulares; a influência da inter-reflexão dos objetos; as oclusões e sombras; e variações na intensidade e cor da fonte de iluminação.

Neste contexto evidencia-se a necessidade por invariância à iluminação, com a obtenção de características da cena e objetos que se mantêm constantes independentemente das condições de iluminação. A difícil tarefa de produzir classificador de cor invariante à iluminação é conhecida como constância de cor. Seu objetivo é de eliminar a influência das variações da luz nas cores observadas por uma câmera (KOSCHAN; ABIDI, 2008).

Uma imagem colorida é matematicamente representada pela seguinte equação:

$$E_k(x, y, \lambda) = \int_{\omega} R(x, y, \lambda) L(\lambda) S_k(\lambda) d\lambda \quad (2.2)$$

Em que:

- k – Representa o canal da imagem e do sensor ($k = R, G, B$);
- λ – Comprimento de onda da luz;
- ω – Espectro visível da luz;
- $E_k(x, y, \lambda)$ – A imagem associada ao canal correspondente;
- $R(x, y, \lambda)$ – A função de refletância da superfície;
- $L(\lambda)$ – As propriedades da iluminação;
- $S_k(\lambda)$ – As características do sensor para o canal correspondente.

Em resumo, uma imagem colorida é formada pelo resultado da interação da fonte de luz e sua distribuição espectral ($L(\lambda)$), com a superfície do objeto que reflete uma fração desta luz incidente ($R(x, y, \lambda)$) e a sensibilidade do sensor da câmera ($S_k(\lambda)$) que capta este estímulo resultante. Estas interações são então traduzidas em valores escalares em RGB, ao serem integradas ao longo do espectro visível (ω) para cada canal k (AGARWAL et al., 2006). Vide representação da Figura 5.

Figura 5: A luz que atinge a superfície é refletida para a câmera onde é amostrada nos sensores vermelho, verde e azul. (Figura adaptada de Lukac e Plataniotis (2007))

Abordagens de constância de cor apenas são possíveis se restrições ou suposições forem feitas sobre as estruturas da cena. Ao estimarmos os elementos que compõem a imagem, as influências da iluminação ou objeto sobre as cores ficam mais claras e esforços

podem ser tomados para descontar estes efeitos da iluminação e gerar cores mais puras (AGARWAL et al., 2006; GIJSENIJ; GEVERS; Van De Weijer, 2011).

De acordo com a formulação descrita para imagens coloridas, os algoritmos de constância de cor fazem uso de suposições que podem ser caracterizadas em três classes:

1. Suposições baseadas nos sensores – Através de cuidadosa análise dos sensores e de procedimentos de calibração, a sensibilidade dos sensores pode ser estimada.
2. Suposições baseadas na reflectância da superfície – Nesta frente considerações como superfícies com refletâncias lambertianas e idealmente difusas são comuns, mas podem ser condições pouco prováveis em situações reais.
3. Suposições baseadas na iluminação - Diversas condições são propostas em relação às fontes luminosas nos diferentes algoritmos, desde considerar iluminações espacialmente uniformes ou homogêneas, ou de característica acromática até considerações sobre a quantidade de fontes de luz (AGARWAL et al., 2006).

Em geral, quanto mais restrito o espaço de inferência e mais fortes as suposições, maior a probabilidade de identificar um método eficaz de constância luminosa para a proposta aplicação. Por consequência, condições e cenas com poucas restrições apresentam um grande desafio para identificação de um método capaz de manter estabilidade em operação.

2.4 Abordagens de segmentação de cor

Segmentação por cor, consiste em um caso particular do processo de segmentação, em que o objeto de interesse e seus respectivos píxeis são agrupados e diferenciados da cena em função de suas características cromáticas (GONZALEZ; WOODS et al., 1992). Inúmeras possibilidades para este processo existem, sendo sua operação dependente basicamente de dois fatores:

- Representação do pixel, isto é, a forma que o pixel transmite suas informações de cor e como seu valor é constituído. Esta atribuição ao valor do pixel, pode estar associada diretamente a um espaço de cor específico ou a associações mais livres entre seus canais, como operações matemáticas entre seus componentes.
- Critérios de segmentação, que define a estratégia pela qual serão classificados os píxeis da imagem em objeto de interesse e fundo. Delimitando como os agrupamentos serão realizados.

Como critério de classificação duas principais estratégias se destacam pela sua elevada utilização, seu baixo custo computacional e ausência de banco de dados e processos

de treinamentos. A primeira e mais simples é a segmentação por limiar manual, que consiste na direta determinação dos limites de corte que compreendem o grupo de interesse. A segunda consiste na limiarização por Otsu, providenciando um valor de corte automático e dinâmico, mas altamente dependente da distribuição de intensidades da imagem e da separabilidade dos grupos de interesse, promovendo melhores resultados quanto maior a distinção das características dos grupos.

Em ambos os critérios a representação do pixel tem papel fundamental na resposta da segmentação. Assim diversos modelos de cor, que consistem em sistemas de coordenadas para representar os valores de cor da imagem, assim como manipulações de seus canais, provêm formas de aumentar a separabilidade de píxeis de interesse e fundo. Além dos modelos mais conceituados baseados em representações motivadas por hardwares e normas outros modelos são provenientes de aplicações particulares de processamentos de imagens e de resultados experimentais, possuindo características distintas de invariância a iluminação.

A relevância da análise das abordagens tem três principais motivações: diferentes modelos apresentam níveis distintos de sensibilidade à variação das condições ambiente de iluminação; a diferença na representação dos píxeis para cada espaço influência na separabilidade e conseqüentemente na segmentação do objeto, e por fim a conversão entre modelos de cor e a facilidade de manipulação de seus valores influenciam no custo computacional do processamento da imagem ([GARCÍA-MATEOS et al., 2015](#)).

Desta forma os tópicos subsequentes irão cobrir os fundamentos teóricos dos modelos de cor que foram consideradas para a campanha experimental.

2.4.1 Modelo RGB

É um modelo baseado na teoria tricromática, de que qualquer cor pode ser representada pela sobreposição de 3 cores primárias, sendo neste modelo as cores Vermelho (R), Verde (G) e Azul (B). Sua representação é geralmente realizada por meio de um modelo cartesiano através de um cubo, onde os três vértices dos eixos são as cores primárias, os outros três são as cores secundárias, a origem é o preto e o vértice extremo à mesma é o branco. Esta representação usualmente possui seus valores normalizados, isto é, entre 0 e 1.

Os hardwares mais convencionais de captura de imagem utilizam o modelo RGB como base de seu sistema, em câmeras digitais este modelo caracteriza-se por alta acessibilidade e baixo custo, o que vai de encontro aos objetivos propostos pelo presente estudo.

As aquisições de imagens coloridas nestas câmeras funcionam de forma similar à aquisição das imagens monocromáticas. A diferença é que os estímulos gerados por cada espectro de cor (verde, vermelho e azul) são separados e capturados independentemente,

seja pela adição de filtros ópticos um para cada cor, seja pela utilização de prismas semitransparentes que separam as cores para serem lidas em sensores independentes. Em resumo, cada valor do componente RGB é dado pela excitação causada pela luz do objeto associado à sua respectiva cor.

2.4.2 Modelo HSV

O modelo RGB assemelha-se ao processo de identificação do olho humano das cores pois tem alta sensibilidade às mesmas cores primárias (vermelho, verde, azul). Entretanto, seu modelo não possui uma interpretação prática das cores; este e outros modelos que se baseiam na teoria tricromática não são tão intuitivos. Para tentar expressar as noções de cor, alguns modelos foram propostos baseando-se na percepção humana das cores (GONZALEZ; WOODS et al., 1992). Esta pode ser dividida em duas classes:

- Acromática – percepção apenas da intensidade luminosa, representada em níveis de cinza, variando do branco ao preto;
- Cromática – percepção dos aspectos de cor;

O modelo HSV se associa a percepção humana, e 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 está em 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. Esta relação é interessante pois permite a aplicação de certas ferramentas e técnicas de processamento de imagens monocromáticas em imagens coloridas.

A representação dos parâmetros matiz e saturação são geralmente ilustrados por um círculo, como pode ser observado na Figura 6. A matiz está associada ao ângulo e, conseqüentemente, às cores, sendo 0° usualmente associado à cor vermelha; já a saturação está associada ao tamanho do vetor, sendo o valor 0 o equivalente à total diluição da cor.

Figura 6: Representação circular de matiz e saturação. Figura adaptada de [Gonzalez, Woods et al. \(1992\)](#)

Dada uma imagem em RGB, a conversão para o modelo HSV pode ser feita, considerando que os valores estão normalizados (intervalo de 0 à 1), aplicando as seguintes formulas para cada um dos píxeis:

- *Value*:

$$V \leftarrow \max(R, G, B) \quad (2.3)$$

- *Saturation*:

$$S \leftarrow \begin{cases} \frac{V - \min(R, G, B)}{V} & \text{se } V \neq 0 \\ 0 & \text{caso contrário} \end{cases} \quad (2.4)$$

- *Hue*:

$$H \leftarrow \begin{cases} 60(G - B)/(V - \min(R, G, B)) & \text{if } V = R \\ 120 + 60(B - R)/(V - \min(R, G, B)) & \text{if } V = G \\ 240 + 60(R - G)/(V - \min(R, G, B)) & \text{if } V = B \end{cases} \quad (2.5)$$

Os resultados destas contas retornam os valores de matiz em ângulos, e de saturação e valor também normalizados entre 0 e 1. Nota-se que devido à familiarização do modelo com a percepção natural, sua aplicação torna-se intuitiva, motivando e promovendo seu uso como ferramenta para o processamento de imagens coloridas. Por sua fácil interpretação, implementação e eficiência esta abordagem é uma das mais difundidas e usadas para segmentação através da cor e por este motivo será considerada como abordagem base para as análises na campanha experimental.

2.4.3 RGB normalizado (rgb)

Espaço de cor baseado no RGB, que busca eliminar as informações de brilho do sistema tridimensional convencional, formando um modelo bidimensional com apenas as

informações cromáticas (KOSCHAN; ABIDI, 2008). Para tanto realiza para cada pixel a normalização das respostas dos canais em relação a intensidade, da seguinte forma:

$$r = \frac{R}{(R + G + B)}; \quad g = \frac{G}{(R + G + B)}; \quad b = \frac{B}{(R + G + B)}; \quad \text{em que } (r + g + b) = 1 \quad (2.6)$$

Devido a relação entre as variáveis imposta na última equação, este espaço pode ser descrito por duas de suas variáveis, geralmente r e g , sendo também chamadas de coordenadas cromáticas.

2.4.4 XYZ

Modelo constituído pelos valores de tri-estímulos conhecidos como XYZ, constitui a base dos modelos tricromáticos e de diversos outros espaços de cor. Foi desenvolvido em 1931 pela Comissão Internacional de Iluminação (CIE-*Commission internationale de l'éclairage*) sendo o Sistema internacional de referência de medição de cores (KOSCHAN; ABIDI, 2008).

O espaço definiu de forma experimental os padrões, referências e medições que cobrem todo o espectro visível de cores de um ser humano comum, e foi inspirado na percepção e estímulo das ondas luminosas pelo olho. O parâmetro Z é uma aproximação do foto receptor humano (cones) para ondas curtas, já o X é uma mistura dos receptores de ondas longas e médias, sendo o Y a luminância ou brilho da cena (GARCÍA-MATEOS et al., 2015). Nota-se portanto, que este é um modelo com características invariantes a iluminação, dada a separação dos aspectos cromáticos e acromáticos.

Existem diversas conversões do modelo RGB para o XYZ, que dependem da condição de iluminação pretendida. A conversão utilizada nos experimentos foi a CIE XYZ Rec 709 com ponto branco em D65, cuja conversão pode ser representada como:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \leftarrow \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,950227 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.7)$$

2.4.5 $L^*a^*b^*$ e $L^*u^*v^*$

Os modelos $L^*a^*b^*$ e $L^*u^*v^*$ foram definidos pelo CIE para aplicações industriais de cores, sendo ambos derivados diretamente do modelo XYZ. São conhecidos como espaços de cor uniformes, pois seus canais foram estabelecidos de forma que as diferenças nas coordenadas de cores correspondessem a mesma percepção visível de tom e saturação das cores (KOSCHAN; ABIDI, 2008).

Nos dois modelos temos a separação da representação das cores com a luminosidade, sendo este último 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 respectivamente (GARCÍA-MATEOS et al., 2015).

Sua formulação depende do espaço XYZ utilizado e portanto possui diversas variações, para o projeto optou-se pela conversão descrita no tópico anterior, sendo as demais descritas por (POYNTON, 2018):

$$L \leftarrow \begin{cases} 116 * Y^{1/3} & \text{para } Y > 0,008856 \\ 903,3 * Y & \text{para } Y \leq 0,008856 \end{cases} \quad (2.8)$$

$$\begin{aligned} a &\leftarrow 500(f(X) - f(Y)) \\ b &\leftarrow 200(f(Y) - f(Z)) \end{aligned} \quad (2.9)$$

$$f(t) = \begin{cases} t^{1/3} & \text{para } t > 0,008856 \\ 7,787t + 16/116 & \text{para } t \leq 0,008856 \end{cases} \quad (2.10)$$

$$\begin{aligned} u' &\leftarrow 4 * X / (X + 15 * Y + 3Z) \\ v' &\leftarrow 9 * Y / (X + 15 * Y + 3Z) \\ u &\leftarrow 13 * L * (u' - u_n) \quad \text{onde } u_n = 0,19793943 \\ v &\leftarrow 13 * L * (v' - v_n) \quad \text{onde } v_n = 0,46831096 \end{aligned} \quad (2.11)$$

Vale ressaltar que os valores de saída devem ser ajustados de forma a compreender o intervalo do dado especificado para as imagens.

2.4.6 YCrCb

YCrCb é um espaço de cores muito utilizado em compressão de imagens e em comunicações, é por exemplo utilizado nos padrões JPEG e MPEG. Caracteriza mais um modelo em que a luminosidade e a cromaticidade são representados separadamente. Neste o Y , proveniente do modelo XYZ, determina os aspectos acromáticos e o Cr e Cb os aspectos cromáticos, sendo estes essencialmente os canais R e B normalizados em relação a intensidade (GARCÍA-MATEOS et al., 2015). A formulação utilizada no estudo foi (POYNTON, 2018):

$$\begin{aligned} Y &\leftarrow 0,299 \cdot R + 0,587 \cdot G + 0,114 \cdot B \\ Cr &\leftarrow (R - Y) \cdot 0,713 + 0,5 \\ Cb &\leftarrow (B - Y) \cdot 0,564 + 0,5 \end{aligned} \quad (2.12)$$

Sendo as entradas e saídas compreendidas no intervalo de 0 e 1.

2.4.7 Espaço de cor l1,l2,l3

O modelo l1,l2,l3 foi proposto e testado por [Gevers e Smeulders \(1999\)](#) e foi desenvolvido com intuito de criar um modelo invariante à luminosidade para objetos tanto foscos quanto brilhantes, reduzindo os efeitos de destaques luminosos, orientação da câmera e superfície, assim como variações de intensidade.

Em resumo, a formulação parte do princípio de que o reflexo da fonte luminosa no objeto gera destaques luminosos que, a partir de dado ponto de distanciamento, começam a sofrer a contribuição da reflexão do corpo e de sua superfície e passam, portanto, a apresentar valores cromáticos similares ao objeto.

De forma similar à matiz (H) do modelo HSV, este modelo calcula a direção da cor no modelo RGB, detectando a cor do objeto mesmo com a influência da intensidade causada pela reflexão da fonte luminosa. Esta abordagem, entretanto, não suporta reflexões mais intensas como em condições de reflexão total da fonte luminosa, isto é, quando não há a interação da superfície. A extensão deste efeito está muitas vezes relacionada ao brilho do objeto, sendo que objetos com superfícies mais ásperas geram menores áreas acromáticas.

O modelo é constituído pelos canais l1, l2, l3 e sua formulação pode ser vista abaixo:

$$\begin{aligned} l1 &= \frac{(R - G)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2}, \\ l2 &= \frac{(R - B)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2}, \\ l3 &= \frac{(G - B)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2}, \end{aligned} \quad (2.13)$$

O modelo proposto e outros sete modelos foram testados pelos autores em um conjunto de 70 imagens fazendo o uso de um banco de 500 imagens coloridas e tridimensionais de referência, de objetos cotidianos em um fundo branco sobre iluminações artificiais simulando a luz solar. Os diferentes modelos foram avaliados e comparados em função do poder de reconhecimento de objetos pela análise de correspondência dos histogramas das imagens teste com o banco de dados.

O estudo concluiu que o modelo l1, l2, l3 mostrou o maior poder discriminativo sob condições de iluminação branca, seguido por perto do modelo H (Matiz). Sua aplicação também se mostrou eficaz para redução dos efeitos de orientação da superfície do objeto, destaques luminosos, variações na direção e intensidade da fonte luminosa. Entretanto, demonstrou-se vulnerável aos efeitos das variações de cor da fonte luminosa e inter-reflexões. A abordagem pixel a pixel desta abordagem, seu baixo custo computacional e seus resultados promissores em alguns dos grandes desafios de segmentação são alguns dos

fatores que justificam a seleção deste modelo como um dos avaliados no estudo.

2.4.8 Espaço de cor I1,I2,I3

O espaço de cor I1, I2, I3, é um modelo de cor obtido empiricamente, por [Ohta, Kanade e Sakai \(1980\)](#), pela simplicidade de aplicação e seus bons resultados na segmentação de imagens coloridas, é frequentemente utilizado em processamento de imagens ([KOSCHAN; ABIDI, 2008](#)). Para a obtenção deste modelo, um algoritmo de segmentação com limiarização recursiva foi aplicado a um conjunto de oito distintas imagens coloridas. Ao fim das iterações de todas as imagens o resultado final revelou que estas cenas poderiam ser segmentadas de forma muito similar se fossem representadas por um modelo formado por I1, I2 e I3 como segue abaixo:

$$I1 = \frac{(R + G + B)}{3}; \quad I2 = \frac{(R - B)}{3}; \quad I3 = \frac{(2G - R - B)}{4} \quad (2.14)$$

Nota-se que o modelo se trata de uma simples transformação linear do modelo original de cor (R, G, B), garantindo velocidade computacional e estabilidade, devido à ausência de singularidades, comuns em modelos não lineares. Para validar o modelo proposto o artigo discutido em questão também realiza um comparativo do modelo I1, I2, I3 com outros sete modelos convencionais de cor para o mesmo conjunto inicial de oito imagens, mostrando que sua eficiência de segmentação desempenhou sempre igual ou superior aos demais. Por fim o estudo mostrou também que grande parte do poder de segmentação reside nos dois primeiros componentes deste espaço de cor, e que em diversas situações, utilizar apenas I1 e I2 é suficiente para as operações de segmentação.

2.4.9 Espaço de cor I,V1,V2

O espaço de cor proposto é, na realidade, uma transformada similar a sub-etapa da transformação do sistema de coordenada RGB para o HSI descrita por [Pratt \(2001\)](#). Trata-se de uma leve modificação da transformação linear inicial, antes da aplicação das transformadas não lineares. Esta abordagem foi descrita e testada por [Steward e Tian \(1999\)](#), e pode ser representada pela matriz como segue:

$$\begin{bmatrix} V1 \\ V2 \\ I \end{bmatrix} = \begin{bmatrix} \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \\ \frac{-1}{\sqrt{6}} & \frac{-1}{\sqrt{6}} & \frac{2}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.15)$$

Esta transformação trata-se de uma rotação das coordenadas RGB, tal que a coordenada I é colinear ao eixo de intensidade, e os outros dois componentes V1 e V2 são ortogonais e constituem um plano perpendicular a este eixo separando, portanto, os valores de intensidade das informações cromáticas da imagem. Vale destacar que V1 é definido

com um eixo paralelo à lateral do triângulo de cor do modelo RGB, que vai do vértice vermelho ao verde, isto é, os valores de V1 demonstram o nível de verde de determinado pixel da imagem em contraponto à quantidade de vermelho.

No artigo em questão, o poder de segmentação do espaço de cor I,V1,V2 foi comparado com o modelo cromático rgb, sob um conjunto de 80 imagens de ervas daninhas, sendo 40 realizadas em sol nublado e 40 em condições normais de iluminação. Encontraram como resultado uma melhor segmentação do modelo I,V1,V2 independente da condição de iluminação. Este modelo foi escolhido para análise no estudo devido à característica do componente V1 em quantificar o verde, a simplicidade dos cálculos e ao fato desta abordagem ter se mostrado eficaz em uma aplicação similar à proposta no trabalho.

2.4.10 Espaço de cor invariante à iluminação

Diferentemente dos demais modelos tratados até o momento, a abordagem em questão consiste em gerar unicamente um espaço de cor invariante à iluminação. O método é capaz de lidar com os problemas de variação luminosa e sombras, sendo também capaz de discriminar as superfícies da cena. As cores originais da mesma, porém, não são associadas à imagem final. Em geral, temos como saída deste método imagens unidimensionais, com algumas abordagens retratando a geração de espaços bidimensionais.

O método foi apresentado por [Ratnasingam e Collins \(2010\)](#), e sua aplicação em câmeras convencionais, com as usuais respostas de apenas três sensores, foi explorada poucos anos depois por [Ratnasingam e McGinnity \(2012\)](#). Nestes estudos foi proposta a criação do espaço de cor F invariante à iluminação.

A definição deste espaço é realizada através da análise e de suposições referentes às respostas de cada unidade sensora de um dispositivo de captura e das características do iluminante. Sua racional parte do equacionamento básico da resposta de cada sensor, e pode ser expresso como segue:

$$R^{x,E} = \underline{a}^x \cdot \underline{n}^x I^x \int_{\omega} S^x(\lambda) E^x(\lambda) F(\lambda) d\lambda \quad (2.16)$$

Onde temos:

- $R^{x,E}$ - Resposta de um sensor de imagem linear;
- $F(\lambda)$ - Função resposta do sensor aos estímulos espectrais;
- $\underline{a}^x \cdot \underline{n}^x$ - Produto vetorial que representa os fatores geométricos da cena, sendo respectivamente a direção da fonte de luz e a normal da superfície;
- I^x - Intensidade do iluminante no ponto x da cena;

- S^x - Reflectância da superfície no ponto x;
- E^x - Distribuição espectral da fonte de luz;
- Sendo a integração realizada sobre o espectro visível de luz.

A partir deste equacionamento e considerando que a resposta espectral dos sensores é suficientemente estreita, de forma que $F(\lambda)$ possa ser modelado com uma função Delta de Dirac centrada em λ_i , pode-se simplificar a equação para:

$$R^{x,E} = \underline{a}^x \cdot \underline{n}^x I^x S^x(\lambda_i) E^x(\lambda_i) \quad (2.17)$$

Realizando a operação logarítmica em ambos os lados da equação, separando seus componentes e assumindo $G^x = \underline{a}^x \cdot \underline{n}^x$, tem-se:

$$\log R^{x,E} = \log G^x I^x + \log S^x(\lambda_i) + \log E^x(\lambda_i) \quad (2.18)$$

Tem-se, portanto, para a resposta do sensor a composição de três termos: o primeiro é dependente da geometria da cena e da intensidade do iluminante; o segundo está associado a reflectância da superfície do objeto; e o terceiro depende dos aspectos cromáticos do iluminante. Em ambientes externos com iluminação natural é razoável a aproximação do espectro de iluminação para a de um corpo negro (FINLAYSON; HORDLEY, 2001). Sob esta consideração a equação de Plank e a aproximação de Wien podem ser aplicadas na equação resultando em:

$$\log R_i = \log GI + \log 2hc^2 S_i \lambda_i^{-5} S_i - \frac{h_c}{k_B T \lambda_i} \quad (2.19)$$

Sendo h constante de Plank, c a velocidade da luz, k_B a constante de Boltzmanne T a cor associada a temperatura do corpo negro (RATNASINGAM; COLLINS, 2010).

Por fim nota-se que a partir desta equação é possível eliminar o primeiro e terceiro termos, incorporando a respostas de outros sensores com diferentes sensibilidades espectrais. Com a manipulação adequada das respostas dos canais é possível obter apenas o termo associado à refletância das superfícies, sendo este independente da iluminação. Tem-se com isto o proposto espaço F bidimensional:

$$\begin{aligned} F_1 &= \log R_2 - \{\alpha \log R_1 + \beta \log R_3\} \\ F_2 &= \log R_3 - \{\gamma \log R_1 + \delta \log R_2\} \end{aligned} \quad (2.20)$$

Onde R_1 , R_2 e R_3 são as respostas dos sensores, sendo estes numerados a partir do menor comprimento de onda do espectro luminoso; e α , β , γ , e δ são coeficientes dos canais,

que ao satisfazerem as seguintes equações, removem as indesejadas variações das repostas dos sensores em relação à geometria da cena, à intensidade e distribuição espectral do iluminante:

$$\begin{aligned}\frac{1}{\lambda_2} &= \frac{\alpha}{\lambda_1} + \frac{\beta}{\lambda_3} \\ \frac{1}{\lambda_3} &= \frac{\gamma}{\lambda_1} + \frac{\delta}{\lambda_2}\end{aligned}\tag{2.21}$$

Sendo λ_1 , λ_2 e λ_3 o comprimento de onda, onde os respectivos sensores possuem o pico de sensibilidade ([RATNASINGAM; MCGINNITY, 2012](#)).

A abordagem proposta e simplificações com apenas um espaço de cor, foram utilizadas em diversos estudos com comprovada eficiência, vide Figuras 7 e 8 ([MCMANUS et al., 2014](#); [UPCROFT et al., 2014](#); [MADDERN; STEWART; NEWMAN, 2014](#)).

Figura 7: Aplicação do espaço de cor invariante à iluminação. (Figura reproduzida de [Maddern, Stewart e Newman \(2014\)](#))

Figura 8: Aplicação do invariante para auxiliar na classificação de elementos urbanos (Figura reproduzida de [Upcroft et al. \(2014\)](#))

Como problemas da sua aplicação temos que a abordagem funciona apenas para cenas iluminadas por uma única fonte ([RATNASINGAM; MCGINNITY, 2012](#)). Da mesma forma, a transformação adiciona ruídos à imagem de saída ([MCMANUS et al., 2014](#)), além do fato de que eventualmente diferentes reflectâncias podem estar confundidas no espaço de cor gerado.

2.4.11 Índices de vegetação

Em estudos geológicos, biofísicos e mesmo na agricultura, os índices de vegetação são termos bem-conceituados. Tratam-se de valores resultantes de combinações de diferentes bandas espectrais com intuito de acentuar e diferenciar a vegetação dos demais elementos da imagem, como solo e água. Em sua maioria, estes índices fazem uso de respostas de sensores no infravermelho próximo (near infra red – NIR), além das cores padrão do espectro visível (JACKSON; HUETE, 1991).

Além dos índices convencionais, o grupo de Woebbecke et al. (1995) foi um dos primeiros a estudar o uso de índices derivados apenas das coordenadas cromáticas, ou seja, fazendo uso das bandas espectrais vermelha, verde e azul. Desta forma, além de remover a necessidade de hardware especializado capaz de capturar infravermelho próximo, ele tornou os índices mais intuitivos, destacando o verde característico das plantas na cena. Em seu estudo ele propôs e avaliou o uso de cinco diferentes índices de cor, sendo quatro baseados em combinações das coordenadas cromáticas e um baseado em um cálculo de matiz (Hue) modificado. Estes podem ser representados, sem os índices de linha e coluna da imagem, pelas seguintes operações (MEYER; NETO, 2008; MEYER, 2011):

1. $r - g$
2. $g - b$
3. $\frac{(g-b)}{(r-g)}$
4. $2.g - r - b$ (ExG)
5. $Hue = \cos^{-1} \left[\frac{2R-G-B}{2(R^2+G^2+B^2-RG-GB-RB)^{1/2}} \right]$

A avaliação destes métodos por Woebbecke et al. (1995) revelou que o índice 4, conhecido como excess green (ExG) apresentaram bons resultados com a geração de imagens quase binárias, sendo este amplamente citado e usado, servindo muitas vezes como base comparativa para métodos propostos de segmentação (GITELSON et al., 2002; LAMM; SLAUGHTER; GILES, 2002; MAO; WANG; WANG, 2003; GUERRERO et al., 2012; TORRES-SÁNCHEZ et al., 2014; JIANG; WANG; LIU, 2015; LIU et al., 2016). Poucos anos depois Meyer, Hindman e Laksmi (1999) propuseram um índice alternativo conhecido por *excess red* (ExR) que, em contraponto, pretendia gerar destaque ao solo e resíduos, sendo definido por:

$$ExR = 1, 4.r - b \quad (2.22)$$

A Figura 9 abaixo, demonstra os efeitos da aplicação dos índices discutidos, *excess green* e *excess red*, sob diversas condições de solo.

Figura 9: Mudanças de planta de soja, (a,b,c) imagens originais; (d,e,f) *excess green* (ExG); (g,h,i) *excess red* (ExR). (Figura reproduzida Meyer e Neto (2008).)

Outros índices de cores foram propostos para separar plantas do solo e resíduos, como o *normalized vegetation index* (NDI) de Perez et al. (2000) que faz uso apenas dos canais verde e vermelho sob a seguinte forma:

$$NDI = \frac{G - R}{G + R} \quad (2.23)$$

Este coeficiente apresentou resultados melhores se a equação fosse incrementada por um e então multiplicada por um fator de 128. Outro índice de destaque é o *excess green minus excess red* (ExG-ExR), descrito e avaliado por Meyer e Neto (2008), sendo seu resultado obtido pela simples subtração dos dois índices envolvidos, nesta pesquisa este método foi avaliado juntamente com o ExG e NDI que, além de não precisar da etapa de limiarização, apresentou os melhores fatores de qualidade de segmentação, seguido pelo ExG, ficando, portanto, o NDI com os piores fatores.

Os índices de cores têm se mostrado menos sensíveis às variações luminosas e com potencial de trabalhar bem mesmo sob diferentes condições de solo. Sabe-se, entretanto, que situações particulares de iluminação, como grandes proporções de vermelho, afetam muito o desempenho destas abordagens, assim como as já conhecidas dificuldades presentes no ambiente externo, como sombras e destaques luminosos (CAMPBELL; WYNNE, 2011). Estes métodos possuem grande histórico de aplicação no contexto agrícola com satisfatórios

resultados, aplicabilidade à câmeras convencionais, baixo custo computacional e indícios de invariância à iluminação.

2.5 Abordagens de Constância de Cor

Os tópicos subsequentes irão cobrir os conceitos básicos de algumas das abordagens mais conceituadas de constância de cor destacando a relevância e aplicabilidade das mesmas para o estudo.

2.5.1 Abordagem por referência

No tratar de constância de cor as abordagens podem ser basicamente categorizadas em duas frentes, as abordagens pré-calibradas e abordagens baseadas em dados. Este tópico se refere a uma única abordagem pré-calibrada a ser avaliada no estudo. Isto implica que as características do sensor são determinadas e sua resposta é avaliada sob diferentes condições de iluminação (AGARWAL et al., 2006). Abordagens desta natureza requerem a caracterização do sensor, a dependência de hardwares específicos e de aparatos caracterizados para a cena, dificultando a acessibilidade de sua aplicação.

Entretanto algumas abordagens mais simples e com menor custo computacional podem ser destacadas, baseando-se principalmente no conceito da transformação diagonal, também conhecida como constância de cor por coeficientes. Esta consiste em dizer que a constância de cor de uma cena pode ser obtida com o ajuste individual das respostas dos sensores por fatores adequados (FINLAYSON, 1995). Este conceito é a ideia central de diversas abordagens de constância de cor, fundamentadas na hipótese de von Kries e avaliadas por West e Brill (1982).

Para auxiliar na estimativa dos coeficientes utiliza-se um objeto referência cujas características de cor sob um iluminante conhecido já estão completamente caracterizados. Assim a observação desta referência sob condição desconhecida, permite o cálculo da matriz diagonal que irá proporcionar a transformação para condição iluminante conhecida, ou seja, para a condição em que as propriedades da superfície não dependem do iluminante. Na forma matemática este processo pode ser expresso como (FINLAYSON, 1995):

$$\begin{bmatrix} d_1 \\ d_2 \\ d_3 \end{bmatrix} = \begin{bmatrix} c_1 & 0 & 0 \\ 0 & c_2 & 0 \\ 0 & 0 & c_3 \end{bmatrix} \cdot \begin{bmatrix} p_1 \\ p_2 \\ p_3 \end{bmatrix} \quad (2.24)$$

Sendo d_i a resposta do i -ésimo sensor sob um iluminante desconhecido, p_i um descritor da superfície do objeto sem a influência do iluminante, e c_i os coeficientes associados ao iluminante que geram esta transformação.

Em resumo a abordagem por referência faz uso de um objeto conhecido para obter-se os coeficientes da transformada diagonal, estimar a condição do iluminante e por fim gerar uma imagem com constância de cor. A simplicidade da abordagem incentiva sua aplicabilidade, mas seu modelo possui comprovada falta de acurácia, sendo que modelos mais completos e complexos existem com melhorias nas respostas de constância de cor (FINLAYSON; DREW; FUNT, 1994; BARNARD; CIUREA; FUNT, 2001).

2.5.2 Gray World e Scale by Max

Ambos os métodos tratados neste tópico são considerados como simples e tradicionais para constância de cor; entretanto, são amplamente utilizados como modelos para comparações entre métodos de invariância luminosa e seus resultados se mostram razoáveis em grande parte das aplicações (AGARWAL et al., 2006).

O método Gray World é considerado como um dos métodos mais antigos e básicos. Baseia-se na suposição de que a média da reflectância das superfícies de uma cena típica é cinza; isto traduz-se em câmeras RGB a média das intensidades nos canais vermelho, verde e azul devem ser iguais. Esta abordagem, portanto, infere que a média das intensidades refletidas correspondem às cores do iluminante. Esta estimativa, por sua vez, pode ser utilizada para calcular as cores originais da cena sem a influência da iluminação, atingindo a desejada constância luminosa (BUENAPOSADA; BAUMELA, 2001; LAM, 2005; LUKAC; PLATANIOTIS, 2007). Esta abordagem geralmente falha quando a cena é constituída por alguma cor predominante, pois fere a suposição que a média das cores da imagem é cinza. Outra vulnerabilidade do método ocorre quando o iluminante não é único ou sua influência sobre a imagem não é constante (BUENAPOSADA; BAUMELA, 2001; LUKAC; PLATANIOTIS, 2007). A aplicação mais básica deste método baseia-se na simples divisão de cada canal de cor pelo seu valor médio:

$$R \rightarrow \frac{R}{\mu(R)}, \quad G \rightarrow \frac{G}{\mu(G)}, \quad B \rightarrow \frac{B}{\mu(B)} \quad (2.25)$$

Sendo $\mu(R), \mu(G), \mu(B)$, a média calculada de todos os pontos dos canais vermelho, verde e azul respectivamente (LUKAC; PLATANIOTIS, 2007).

Diversas outras aplicações e variações baseadas no mesmo princípio emergem da literatura, trazendo melhorias nos resultados da imagem. Destas, uma em especial, ajusta adicionalmente a média de cada um dos canais para a média total da imagem, também obtida com a média das médias dos canais. Este método calcula a razão da média total pela média do respectivo canal e multiplica este ganho pelo conjunto original de píxeis do canal. A seguir exemplifica-se a aplicação do método para o canal vermelho, sendo a

lógica replicável a qualquer canal, tem-se:

$$R \rightarrow R \frac{\mu(total)}{\mu(R)} = R \frac{\mu(\mu(R), \mu(G), \mu(B))}{\mu(R)} \quad (2.26)$$

Em casos em que a suposição de iluminante cinza não é justa, uma alternativa pode ser assumir a estimativa do iluminante como o valor máximo de cada canal ao invés do valor médio. Esta abordagem é conhecida como *Scale by Max* ou algoritmo do máximo RGB, e sua aplicação é similar à descrita para o algoritmo de Gray World com a simples substituição dos valores médios dos canais pelo máximo valor (AGARWAL et al., 2006; LUKAC; PLATANIOTIS, 2007).

Esta estimativa é geralmente mais precisa que os métodos de Gray World. Entretanto, falhas são comuns quando condições físicas da cena geram alguma confusão dos máximos, como em casos de objetos de alto brilho que geralmente possuem os pontos de maior intensidade, mas que podem carregar as próprias cores refletidas junto às cores da fonte luminosa.

2.5.3 Retinex

Retinex foi o primeiro algoritmo proposto para descrever a habilidade de constância de cor do sistema visual humano e foi descrita por Land e McCann (1971). A teoria proposta foi chamada de teoria retinex, nome proveniente da combinação das palavras retina e córtex, devido ao fato de que sua elaboração partiu inicialmente de estudos e observações dos aspectos neurofisiológicos da percepção humana e do sistema de visão em imagens mondrianas sob diferentes fontes luminosas.

Os autores então estabeleceram que o nosso sistema de visão não percebe a intensidade absoluta da luz, mas sim a intensidade relativa, isto é, consideramos as características de intensidade da refletância das superfícies independentemente das condições de iluminação. Um exemplo de como nosso sistema de visão é relativo pode ser avaliado na ilusão de ótica da Figura 10, onde o quadrado A e D possuem a mesma intensidade. Além do estudo fisiológico, a teoria foi proposta para obtenção de uma análoga constância luminosa em sistemas de visão de máquina, caracterizando o Retinex como uma estratégia para processamento de imagem, gerando realce de luminosidade e cor para imagens digitais (AGARWAL et al., 2006; KOSCHAN; ABIDI, 2008; PETRO; SBERT; MOREL, 2014).

Neste primeiro trabalho, Land e McCann (1971) propuseram um complexo algoritmo que envolvia o processamento ao longo de caminhos na imagem, para cálculo da intensidade relativa. Diversas interpretações e estudos sugeriram a partir deste trabalho inicial, mas estes podem ser divididos em dois grandes grupos.

O primeiro ainda explora a ideia de luminosidade relativa fazendo a computação de diversos caminhos na imagem, ou pela comparação de píxeis coloridos com conjuntos

Figura 10: Os quadrados A e B da imagem possuem exatamente o mesmo tom de cinza, mas a intensidade dos arredores de B o associa a cor clara. Edward H Adelson

aleatórios de píxeis. Já o segundo grupo faz uso de máscaras e convolução ou técnicas de variacionais para computar o contraste local (PETRO; SBERT; MOREL, 2014). Os algoritmos do primeiro grupo possuem alta complexidade e instabilidade, com elevado impacto nos tempos de processamento do sistema.

As abordagens do segundo grupo, que tem como ponto original o trabalho posterior de Land (1983). De forma geral, estes algoritmos realizam uma espécie de filtro passa alta na imagem. Em termos práticos, esta implementação estima através da razão entre o valor do pixel e o valor médio da vizinhança, a iluminação da imagem. Este valor médio da região pode ser estimado de diversas maneiras, seja através de diferentes abordagens e formulas, seja pela escolha de cada um dos parâmetros a elas associadas.

Diversos métodos foram e estão sendo propostos ao longo do tempo, mas um dos mais comuns e aceitos é a aproximação através de uma formulação ou convolução gaussiana. Sua utilização foi proposta por Jobson e Woodell (1995) e sua expressão pode ser retratada como segue:

$$F(x, y) = Ce^{\frac{-(x^2+y^2)}{2\sigma^2}} \quad (2.27)$$

Onde σ é o desvio padrão do filtro, e determina a quantidade de detalhe que será retida; e C é um fator de normalização da função tal que:

$$\int F(x, y) dx dy = 1 \quad (2.28)$$

Fazendo uso deste operador gaussiano como função de cálculo de região normalizada,

um primeiro método, conhecido como *Single-Scale Retinex* (SSR) pode ser explorado (RAHMAN; JOBSON; WOODSELL, 2004; PETRO; SBERT; MOREL, 2014). Sua forma matemática, a ser estendida para todos os canais da imagem, é dada por:

$$R_i(x, y) = \log I_i(x, y) - \log (I_i(x, y) * F(x, y)) \quad (2.29)$$

Na qual:

- I_i - É a imagem original referente ao i-ésimo canal, sendo geralmente associados aos canais R, G e B;
- R_i - A imagem de saída do algoritmo Retinex referente ao i-ésimo canal;
- F - A função de cálculo de região, responsável por estimar a média dos píxeis vizinhos a um pixel central, sendo no caso das aplicações em estudo a função gaussiana já comentada.

A invariância luminosa desta abordagem é demonstrada ao considerar as seguintes associações e suposições:

1. A consideração clássica de que uma imagem é constituída pela interação da fonte de iluminação (S) e da reflexão da cena (r):

$$I_i(x, y) = S_i(x, y)r_i(x, y) \quad (2.30)$$

2. Da propriedade logarítmica temos que o algoritmo SSR pode ser rescrito como:

$$R_i(x, y) \simeq \log \frac{S_i(x, y)r_i(x, y)}{\bar{S}_i \bar{r}_i} \quad (2.31)$$

Sendo $\bar{S}$ e $\bar{R}$, os valores médios de iluminação e refletância respectivamente.

3. E por fim, considerando a suposição de que a iluminação em uma cena varia suavemente, podendo ser considerada localmente constante. Pode-se assumir que $S_i \simeq \bar{S}_i$ e, portanto:

$$R_i(x, y) \simeq \log \frac{r_i}{\bar{r}_i} \quad (2.32)$$

Nota-se que o resultado final do método não depende da iluminação. Esta formulação também explica porque o método atenua os efeitos das sombras nas imagens (JOBSON; WOODSELL, 1995; PETRO; SBERT; MOREL, 2014).

Esta abordagem, apesar de parecer funcional, possui grande dependência do valor do modificador do filtro gaussiano σ . Este valor, além de não poder ser modelado ou determinado matematicamente, representa uma constante decisão entre utilizar um valor

menor que fornece maiores detalhes e melhorias na dinâmica local ou valores maiores que fornecem cores mais fiéis à imagem original.

Para contornar o problema do balanço e determinação do valor de σ e seus impactos para a imagem de saída do método, uma segunda metodologia foi proposta com o intuito de gerar respostas que garantissem a reprodução das cores originais, mas mantivessem um bom intervalo dinâmico local. Este método é conhecido com *Mutliscale Retinex* (MSR).

Sua abordagem consiste simplesmente em realizar uma média ponderada de diferentes resultados de SSR sob diferentes condições de σ . Este método pode ser representado pela seguinte formula:

$$R_{MSR_i} = \sum_{n=1}^N \omega_n R_{ni} = \sum_{n=1}^N \omega_n [\log I_i(x, y) - \log (I_i(x, y) * F(x, y))] \quad (2.33)$$

Sendo N o número de escalas e ω_n o peso de cada escala e ambos parâmetros arbitrários.

Contudo, em geral as aplicações demonstram que 3 é um número suficiente de escalas, e que resultados consistentes são obtidos com a escolha de um sigma pequeno, um médio e um grande (RAHMAN; JOBSON; WOODDELL, 2004; PETRO; SBERT; MOREL, 2014).

Apesar de representar uma melhora significativa em relação ao método anterior, quando as suposições do método de Gray World não são cumpridas, isto é, quando existe dominância de uma das cores, os resultados de ambos os métodos não são satisfatórios, uma vez que ocorre uma expressiva diminuição na saturação das cores gerando imagens acinzentadas.

Devido a esta característica, os métodos Retinex são muitas vezes acompanhados de métodos para gerar restauração das cores, sendo nesta condição chamados de *Multiscales Retinex with color Restoration* (MSRCR). Para gerar a restauração de cor, inúmeros artigos, estudos e algoritmos são propostos. Segue na sequencia um breve descritivo de alguns dos mais utilizados:

- Ganho e deslocamento (*Gain/Offset*): Uma etapa adicional de restauração de cor é realizada nas saídas do MSR, produzindo-se um ajuste de ganho β e um controle da intensidade da não linearidade por meio de α , conforme representado nas seguintes expressões:

$$\begin{aligned} C_i(x, y) &= \beta [\log \alpha I'_i(x, y)] \\ R_{MSRCR_i}(x, y) &= C_i(x, y) R_{MSR_i}(x, y) \end{aligned} \quad (2.34)$$

Sendo C_i a função de restauração de cor, I'_i as coordenadas cromáticas (rgb) e a R_{MSRCR_i} imagem de saída do algoritmo.

- Ganho e deslocamento canônico: Em termos práticos, consiste na readequação da distribuição dos píxeis ao longo da imagem, sendo que píxeis posicionados nas extremidades são limitados a valores máximos e mínimos, e demais valores são reajustados de forma a ocupar ao máximo este intervalo (RAHMAN; JOBSON; WOODDELL, 2004; PETRO; SBERT; MOREL, 2014). Sua formula é expressa como segue, sendo G e b os valores de ganho e deslocamento respectivamente:

$$R_{MSRCR_i}(x, y) = G[R_{MSRCR_i}(x, y) - b] \quad (2.35)$$

Uma abordagem baseada neste princípio de restauração de cor chamada de Simplest Color Balance e proposta por Limare et al. (2014) será utilizada nos experimentos.

- *MSR with chromaticity preservation* (MSRCP): Esta abordagem aplica o método de MSR apenas sobre uma imagem de intensidade da cena, calculada a partir da média dos valores de cada canal de cor. Em sequência, multiplica a resposta aos fatores calculados que irão restaurar a cromaticidade original da imagem. Este equacionamento é descrito abaixo:

$$R_i = I_i \frac{R_i}{I} \quad (2.36)$$

Sendo I o canal intensidade, I_i a imagem original no i -ésimo canal e R_I o resultado da operação de MSR na imagem de intensidade (PETRO; SBERT; MOREL, 2014).

Em suma, o método apresenta bons resultados de constância de cor gerando imagens de ótima aparência, mesmo sob condições originais precárias e sob condições adversas tais como sombras e baixa iluminação, a exemplo ver Figura 11. Entretanto, a sua grande variedade de abordagens, seu processamento elevado e grande dependência da definição de parâmetros livres de grande influência no desempenho do algoritmo, levantam desafios em sua implementação.

2.5.4 Mapeamento Gamut

O mapeamento gamut é uma abordagem de constância de cor que foi introduzida por Forsyth (1990). Baseia-se no sistema de visão humano e na premissa de que, sob um dado iluminante, apenas um número limitado de cores pode ser observado. Por consequência, entende-se que variações nas cores de uma imagem já observada são causadas pela variação da fonte de iluminação. Este conjunto restrito de cores que podem ocorrer sob dado iluminante é conhecido como gamut canônico (C), sendo este obtido por uma etapa de

Figura 11: Topo: Imagem original. Esquerda abaixo: Resultado da MSRCR. Direita abaixo: Resultado da MSRCP. Figura reproduzida de [Petro, Sbert e Morel \(2014\)](#)

treinamento que envolve a observação de diversas superfícies em uma fonte de luz conhecida ([AULAKH; ARORA, 2013](#); [GIJSENIJ et al., 2008](#)).

1. O gamut da fonte de luz desconhecida é calculado, considerando que todas as cores da imagem de entrada são representativas para esta estimativa.
2. Determina-se todos os mapeamentos que aplicados na imagem de entrada irão resultar na convergência do gamut da imagem ao gamut canônico. Pelo fato do gamut do iluminante desconhecido ser estimado por uma única imagem, diversos mapeamentos são obtidos.
3. Selecionar através de estimadores qual mapeamento será utilizado. Diversas abordagens podem ser realizadas nesta etapa, da heurística à médias ponderadas do conjunto de mapeamentos plausíveis.

Métodos baseados em gamut são muito promissores, atingindo alta acurácia de constância de cor e bons resultados de reprodução de cor ([AGARWAL et al., 2006](#); [GIJSENIJ et al., 2008](#)). Entretanto, a abordagem possui os seguintes problemas e dificuldade:

- Exige fortes restrições do iluminante e seu intervalo;

- Aplicável apenas para uma fonte de iluminação com distribuição uniforme;
- Eventualmente nenhuma solução de mapeamento é encontrada e, portanto, o iluminante não pode ser estimado;
- O método não é fácil de ser implementado e seu processamento é altamente laborioso.

Devido os problemas retratados acima, em especial o último item, pelo contraponto com o objetivo de baixo consumo computacional, os métodos baseados em gamut, não serão explorados na campanha experimental.

2.5.5 Abordagens estatísticas

Existem inúmeras abordagens estatísticas para a geração de imagens com constância de cor com bons resultados de acuracidade e adaptabilidade. Entretanto as alternativas exploradas mostraram que em geral estes algoritmos possuem princípios que violam os requisitos do projeto.

As abordagens estatísticas para constância de cor fazem uso de ferramentas estatísticas e da interpretação dos dados das imagens como pertencente a distribuições. Exemplos de aplicações vão desde determinar os estimadores mais prováveis, avaliar respostas de diferentes sensores, estimar a ocorrência dos iluminantes até a estimativa dos iluminantes e refletâncias pela observação de múltiplas imagens de treinamento ([AGARWAL et al., 2006](#)).

Estas abordagens suportam a criação de métodos que buscam contemplar as diversas variações que ocorrem em aplicações reais, como as condições do trabalho proposto, de ambientes externos. Entretanto, alguns métodos, tem como complicadores a necessidade de bancos de dados e conhecimento prévio do iluminante ou cena, apresentando restrições à acessibilidade, custo computacional elevado, e instabilidade por ocasional violação das premissas estatísticas. Estes métodos foram tomados em consideração, mas, devido às dificuldades impostas, estas abordagens não serão avaliadas na campanha experimental.

2.5.6 Aprendizagem de máquina

Os algoritmos de aprendizagem de máquina consistem em abordagens baseadas em dados com resultados promissores. Seu desenvolvimento é realizado a partir da aplicação e, quando bem implementado, pode apresentar ótimos resultados mesmo sob diversas condições de iluminação.

Estes algoritmos são constituídos por duas fases: treinamento e teste. É através do treinamento que o sistema irá responder a informações desconhecidas na etapa de teste, de forma que o conjunto inicial de dados e os algoritmos de treinamento definem o comportamento e desempenho do método ([AGARWAL et al., 2006](#)).

As primeiras abordagens de aprendizagem de máquina para constância de cor foram baseadas em redes neurais ([AGARWAL et al., 2006](#)), mas estudos subsequentes fizeram uso de diversas outras abordagens. Neste contexto pode-se destacar os trabalhos de:

- [Cardei, Funt e Barnard \(2002\)](#), desenvolveram um *multilayer perceptron* (MLP) nos espaços cromáticos e conseguiram comprovados resultados de constância de cor.
- [Ebner \(2004\)](#), que propôs uma rede neural realizando um algoritmo paralelo no espaço RGB.
- [Stanikunas, Vaitkevicius e Kulikowski \(2004\)](#) realizaram uma investigação de constância de cor usando rede neural com comparações ao sistema de visão humana. Concluíram que a informação da cor do fundo é importante para conseguir a constância de cor equivalente a humana em sistemas de visão de máquina.
- [Wen-Chiang e Chwan-Hwa \(1998\)](#) fizeram uso de um método adaptativo chamado *fuzzy assopciated memory* (FAM) para reconhecer a cor de objetos sob imagens de fundo complexas e condições de iluminação variáveis.

Esta abordagem é promissora, mas desenvolver sua aplicação não é uma tarefa fácil. Sua implementação pode possuir instabilidades e seu desempenho depende muito de sua etapa de treinamento que, por sua vez, requer grandes conjuntos de imagens e tempo. Por limitações de tempo e escopo para implementar adequadamente esta abordagem, a mesma não será abordada na avaliação experimental.

2.5.7 Comparativo dos métodos

De forma a sumarizar as informações da maior parte dos métodos de constância luminosas discutidos neste estudo a Tabela 2 adaptada de [Agarwal et al. \(2006\)](#), com tradução livre, resume as vantagens e desvantagens das abordagens discutidas.

Tabela 2: Vantagens e desvantagens algoritmos de constância de cor

Abordagem	Vantagens	Desvantagens
Abordagens pré-calibradas	Apresenta bom desempenho de constância de cor se as características do sensor forem conhecidas.	Requer calibração prévia do sensor.
Abordagens Grey World e Scale by Max	Menor custo computacional. Solução analítica é possível.	Menos confiável e não adaptável. Depende altamente de suposições.
Abordagens Retinex com restauração de cor	Bom desempenho de constância de cor. Bons resultados mesmo em condições precárias	Custo computacional alto. Requer ajuste de parâmetros livres.
Abordagem Gamut	Reprodução da cor é melhor do que demais abordagens.	Custo computacional alto. Depende da sensibilidade do sensor. Assume distribuição luminosa uniforme. Requer conhecimento do intervalo do iluminante.
Abordagens estatísticas	Adaptativa a mudanças nas condições de iluminação. Adistribuição da iluminação é obtida a partir do conhecimento da probabilidade estatística de distribuição. Conhecimento prévio da iluminação não é obrigatório.	Suposições estatísticas são violadas em aplicações em tempo real. Custo computacional alto em termos de tempo.
Abordagens de aprendizagem de máquina	Adaptativa a mudanças nas condições de iluminação. Constância de cor pode ser alcançada pelo conhecimento aproximado da cromaticidade do iluminante.	Algoritmos discutidos são instáveis e alto tempo de treinamento é requerido. Dificil regularizar a estimativa da cromaticidade do iluminante.

2.6 Projeto de experimentos (*Design of experiments*)

Neste tópico será realizada uma visão geral sobre a metodologia que será aplicada na campanha experimental. Trata-se do projeto de experimentos ou experimentos planejados (*design of experiments* – DOE), com destaque ao uso de experimentos fatoriais.

Um experimento pode ser definido como um teste ou sequências de execuções em que mudanças intencionais são criadas em variáveis de entradas de um processo ou sistema para que se possa observar e identificar as razões das mudanças nas saídas. Sob este contexto, por experimento planejado entende-se a cautelosa análise e determinação dos fatores, níveis e estratégias de coletas de dados que compreendem um experimento, de forma a facilitar o entendimento do processo ou sistema e garantir que a devida relação de causa e efeito foi capturada, uma vez que a forma em que os dados são coletados podem influenciar muito a análise e conclusões do experimento.

Com o propósito de gerar o melhor entendimento da relação dos fatores do experimento com os resultados, é recomendada a condução de experimentos fatoriais. Estes são caracterizados por uma estratégia em que os fatores do experimento são variados em conjunto, geralmente em dois diferentes níveis, ao invés de um fator por vez. Esta abordagem garante uma melhor relação entre o número de observações de cada fator, com o número de execuções de testes, além de fornecer relevantes informações de como os fatores interagem entre si (MONTGOMERY, 2012).

Os experimentos fatoriais com dois níveis para cada fator podem ser visualizados de forma gráfica como um quadrado, para abordagens com dois fatores, ou um cubo para experimentos com três fatores, em que cada vértice destas estruturas representa uma condição de teste. Note que os fatores são manipulados em conjunto e sempre aos mesmos níveis. A Figura 12 ilustra esta representação. Experimentos sob esta forma são chamados de fatoriais completos, pois todas as combinações possíveis de fatores são realizadas

Figura 12: Representação gráfica e tabela de um experimento fatorial com 3 fatores (MONTGOMERY, 2012).

3 MATERIAIS E MÉTODOS

Nos próximos tópicos, os elementos que constituem a campanha experimental são percorridos em detalhes. Informações sobre o hardware, software e infraestrutura do experimento são fornecidos assim como o descritivo das métricas para avaliação das abordagens segundo o objetivo do estudo. Na sequência, as etapas, estratégias e expectativas para a campanha experimental são percorridas evidenciando a abordagem sequencial dos estudos. Por fim, a metodologia para análise dos dados será explanada.

3.1 Hardware e software

A determinação dos hardwares do projeto teve como principal motivador o aspecto de acessibilidade, custo e robustez em alinhamento com os objetivos propostos do projeto. Buscou-se no mercado soluções difundidas e básicas de hardware, com desempenho aceitável e custo acessível. Além disto, mais de uma solução foi considerada no estudo, de forma a expandir a aplicabilidade e garantir mais robustez às conclusões do mesmo. Neste pretexto, dois diferentes sistemas de captura foram definidos: uma webcam USB da Logitech modelo c615 e um módulo do sistema embarcado Raspiberry Pi modelo Raspicam rev1.3. Ambos os dispositivos possuem sensores RGB e suas especificações estão sumarizadas na Tabela 3.

Tabela 3: Especificações dos dispositivos de captura.

	Logitech c615	Raspicam rev1.3
Máxima resolução	1920 x 1080	2592 x 1944
Campo de visão	74° (Diagonal)	53,5° H / 41,4° V
Taxa de aquisição máxima	30 fps em 640x480	60 fps em 640x480
Distancia focal	Não informado	3,6 mm
Correção de luz	Sim	Sim
Conexão	USB 2.0	15-pin MIPI CSI connector
Massa	138g	3g
Preço (2017)	70 USD	25 USD

Para algumas das análises dois diferentes sistemas de processamentos foram avaliados, com plataformas e sistemas operacionais distintos, suas configurações podem ser observadas na Tabela 4. Ambos os sistemas propostos, apesar de altamente acessíveis, possuem características muito distintas.

O primeiro trata-se de um computador pessoal de mesa (PC), executando o sistema operacional Windows, com total compatibilidade com o dispositivo de captura webcam, mas incapaz de se comunicar diretamente com o módulo Raspicam.

Já o segundo trata-se de um módulo portátil e de baixo custo, o Raspberrypi 3 modelo B (Rpi), com valor aproximado na data do estudo de 35 USD, que se apresenta

Figura 13: Dispositivos de captura, respectivamente a Webcam Logitech c615 e Raspicam rev 1.3.

Tabela 4: Especificações das unidades de processamento.

	Computador de mesa de alto desempenho	Módulo Raspberry Pi 3 Modelo B:
Processador	Intel Core i7 4790K	64 bits quad-core ARM Cortex-A53
Placa gráfica	Nvidia GeForce GTX 970	VideoCore IV 3D graphics
Memória Ram	16 Gb	1 Gb
Memória	SSD Samsung SSD 850 EVO	cartão microSD 16GB
Sistema operacional	Windows 7	Raspbian Jessie

como uma das alternativas mais populares para aplicações embarcadas (Figura 14). Suas características marcantes incluem tamanho similar ao de um cartão de crédito, massa de apenas 45g, operação em 5 volts e potência de 4W, com saída de áudio, vídeo HDMI e adaptador de internet wi-fi embutido. Além das características de hardware, o módulo executa um sistema operacional aberto e gratuito baseado em Debian, sendo este sistema compatível para operar tanto com a sua câmera dedicada, a Raspicam, como a webcam.

Em relação ao software, novamente duas diferentes abordagens foram utilizadas. Para o desenvolvimento das lógicas dos algoritmos e rápidas avaliações de desempenho, o software de alto nível de programação Wolfram Mathematica (WM) foi selecionado. Este contém uma grande gama de ferramentas de imagens que aceleram muito o tempo de desenvolvimento dos algoritmos. Além disto, o software foi utilizado como um segundo sistema de medição para a análise de desempenho das abordagens do estudo, isto é, este sistema foi avaliado em paralelo ao principal, para providenciar informações de reprodutibilidade dos algoritmos.

Os softwares principais foram implementados fazendo uso da linguagem de programação Python, uma linguagem de relativo alto nível com grande flexibilidade, autonomia e poder computacional, além de altamente difundida e reconhecida. A escolha desta

Figura 14: Raspberrypi 3 modelo B.

linguagem não foi arbitrária e sua utilização visa assegurar a acessibilidade proposta pelo estudo, assegurando sua aplicabilidade e garantindo a portabilidade e uso dos algoritmos em diferentes sistemas. Desta forma, as avaliações experimentais poderão fazer uso dos mesmos códigos, independente do hardware e sistema operacional utilizado.

Os desenvolvimentos dos algoritmos em Python, contam com o uso da biblioteca de funções de programação OpenCV (*Open Source Computer Vision*), que consiste em uma plataforma livre e gratuita, para uso acadêmicos e comercial, para suportar aplicações de visão computacional. Seu desenvolvimento tem como base a eficiência computacional e o uso em aplicações de tempo real, configurando o conjunto de todas as ferramentas e estruturas básicas necessárias para captura, manipulação e processamento de imagens ao longo do estudo.

3.2 Infraestrutura

A campanha experimental foi dividida essencialmente em duas etapas, uma etapa inicial para análise dos parâmetros de testes, validação das métricas e avaliação do sistema de medições, e um segundo conjunto de experimentos para o comparativo e avaliação das estratégias de segmentação. Estes dois momentos do projeto compartilham de um mesmo sistema de captura e aquisição, mas fizeram uso de infraestruturas distintas.

Diversos elementos tiveram de ser definidos e fixados de forma a assegurar a

representatividade dos experimentos com a aplicação e consequentemente a validade das conclusões do estudo. Os aspectos de infraestrutura cobrem desde o local de execução até os componentes que compuseram a cena para a geração das imagens teste. Sua caracterização e justificativas para o estudo serão cobertos na sequência. Já informações referentes a configurações destes elementos nos experimentos serão detalhadas na seção 3.6.

Seguindo a divisão da campanha experimental discutida, dois diferentes locais de testes foram utilizados, o primeiro consiste em um ambiente interno, com controle rígido das condições de iluminação. Já o segundo se aproxima da condição de aplicação, com a execução dos experimentos em ambiente externo e sob as condições naturais de iluminação.

O ambiente interno, consiste em uma sala de paredes brancas sem janelas, com a iluminação proveniente apenas de luzes artificiais. A sala foi iluminada por duas lâmpadas com temperatura de cor de 6800K, ou seja, cromaticidade equivalente a luz do dia e para simulação da luz ao fim do dia uma lâmpada com temperatura de 3000K foi utilizada, sendo todas fluorescentes e com elevado índice de reprodução de cores (IRC). Nesta configuração o objeto de interesse ficou ao longo dos experimentos com uma iluminância aproximada de 161.0 lux e desvio padrão de 5.4 lux, sendo esta variação dentro do esperado para o equipamento.

Já o ambiente externo, é formado por um ambiente aberto com exposição exclusiva a iluminação natural, e portanto, sujeito a suas variações. As capturas nesta condição ocorreram na primeira semana do mês de novembro de 2017, e foram todas realizadas para condição de dia entre as 14:30 e 15:30 horas, para a condição de fim de dia (entardecer) das 19:00 às 19:15 horas e na condição de iluminação crítica (anoitecer) entre 19:45 e 19:50 horas.

O objeto de interesse das imagens, constituído pelas mudas de plantas, caracteriza um aspecto crítico para a operação de segmentação, e consequentemente, para os experimentos. Nos estudos preliminares foram escolhidas três espécies de mudas com características intencionalmente distintas de textura, tamanho, formato das folhas e principalmente de cromaticidade. As mudas selecionadas foram Morango, Hortelã e Manjerição e podem ser visualizadas na Figura 15

Para os experimentos comparativos, optou-se por utilizar mudas de culturas mais expressivas no cenário nacional, de forma a trazer maior relevância e aplicabilidade aos resultados; foram portanto utilizadas mudas de soja e milho. Estas além da elevada importância agrícola possuem características distintas de cromaticidade e textura, sendo a muda de milho mais lisa e com tons de verde levemente mais claros, e a muda de soja mais áspera e escura (vide Figura 16).

Para constituição do fundo da cena, o solo era em sua maioria formado por solo argiloso, conhecido também como terra roxa, por ser um dos solos mais comuns da região

Figura 15: Mudas de Morango, Hortelã e Manjericão respectivamente.

Figura 16: Mudas de Soja e Milho respectivamente, em solo com detritos.

do estudo (estado de São Paulo) além de compatível com as mudas propostas para o experimento.

Em algumas condições experimentais, pequenas porções de substrato orgânico, de cor caracteristicamente preta, foram adicionados para gerar perturbações na cena, assim como fibra de coco, casca de pinus, esfagno, folhas secas, gravetos e pequenas pedras (rever Figura 16). Estes elementos foram adicionados para simular as condições imprevisíveis e conturbadas existentes na aplicação final, sendo chamados genericamente nos experimentos de detritos ou ruídos visuais.

Para reduzir a variação das características do fundo entre as condições experimentais, o solo e demais detritos foram montadas sobre um reservatório de plástico, e para cada condição de captura a muda foi então transplantada ao centro deste cenário. Além disto o posicionamento da câmera em relação a base foi garantido por um suporte ligado ao sistema de aquisição de altura e ângulo ajustável, assegurando controle sobre a pose da captura.

Por fim para a caracterização das condições de iluminação em ambiente aberto e para realização do método de constância de cor por referência, um objeto referência

foi desenvolvido. Este aparato é formado por uma imagem com 4 quadrados, sendo cada um deles constituído pelas cores puras, branco, vermelho, verde e azul, e por uma esfera cinza escuro de 40 mm, garantindo captação da iluminação sob diferentes ângulos com reduzida ocorrência de pontos de saturação em sua captura. Este ultimo componente foi inspirado nos trabalhos de [Vazquez et al. \(2009\)](#), [Ciurea e Funt \(2003\)](#), fazendo inclusive uso da mesma tinta (RAL 7012 - Cinza basalto) utilizada no artigo e banco de dados da *Universitat Autònoma de Barcelona*. A imagem 17 demonstra a referencia em sua aplicação.

Figura 17: Utilização da referência na condição de tempo aberto e nublado respectivamente.

3.3 Métricas

Neste tópico serão exploradas as métricas que foram utilizadas para avaliar e diferenciar as abordagens de segmentação, ou seja, em termos de experimentos planejados, estamos neste momento definindo as variáveis de reposta dos experimentos. A avaliação tem dois diferentes focos, um objetiva-se em avaliar o desempenho de segmentação, mensurando aspectos como sensibilidade, erros e acurácia; já o outro observa o custo computacional e latência das abordagens. Ambas as respostas foram calculadas sobre capturas estáticas da cena, e não vídeos. Entretanto é importante ressaltar que esta abordagem mantém a correlação com a aplicação; uma vez que os códigos desenvolvidos fazendo uso da biblioteca OpenCV foram implementados de forma a processar as imagens das câmeras como se fossem uma sequência de fotos.

3.3.1 Métricas de desempenho de detecção

Para avaliação de desempenho, estratégias associadas a métricas de classificação foram utilizadas. Considerando para tanto a segmentação como uma operação de classificação binária, em outras palavras, como resultado da segmentação cada pixel da imagem é instanciado como pertencente ao grupo planta ou ao grupo fundo.

Diversas métricas de classificação foram utilizadas para avaliar aspectos específicos dos resultados, mas devido o extenso volume de dados da campanha experimental optou-se pela utilização de uma métrica única. Nas primeiras análises o erro total foi utilizado, mas após algumas avaliações sobre o sistema de medição, optou-se pela métrica *F-score* para o comparativo dos resultados. Esta última se mostrou como uma boa alternativa, possuindo alta representatividade ao desempenho de segmentação, ela sumariza as importantes informações de precisão e sensibilidade das abordagens em um único valor.

O *F-score* também conhecido como *F-measure* é definido como a média harmônica entre a precisão e sensibilidade e sua formulação, assim como das demais métricas discutidas podem ser observadas em sequência:

$$\text{erro total} = \frac{FP + FN}{VP + VN + FP + FN} = \frac{FP + FN}{\text{Total de elementos}} \quad (3.1)$$

$$\text{sensibilidade} = \frac{VP}{VP + FN} \quad (3.2)$$

$$\text{precisão} = \frac{VP}{VP + FP} \quad (3.3)$$

$$\text{F-score} = 2 \cdot \frac{\text{precisão} \cdot \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} = \frac{2 \cdot VP}{2 \cdot VP + FP + FN} \quad (3.4)$$

Sendo *VP* (Verdadeiro Positivo) a quantidade de classificações positivas verdadeiras, *VN* (Verdadeiro Negativo) a quantidade de classificações corretas de negativos, *FP* (Falso Positivo) a quantidade de classificações incorretas como Falso Positivo (Erro tipo I) e *FN* (Falso Negativo) a quantidade de classificações perdidas do objeto de interesse (Erro tipo II).

De forma prática, o erro total indica proporção de avaliações incorretas em relação ao total, apesar de intuitiva esta abordagem na aplicação se mostra muito dependente do tamanho do objeto de interesse na cena, configurando uma relação indesejada entre os resultados e a pose. Já a sensibilidade ou revocação, fornece a proporção de classificações corretas como planta em relação ao total de pixels pertencentes as plantas, assim quanto maior a sensibilidade de uma abordagem maior a chance da mesma em classificar corretamente a planta, entretanto erros de falsos positivos não são considerados. A precisão por sua vez observa a proporção de classificações corretas positivas em relação ao total de classificação positivas, ou seja, quanto maior a precisão maior a certeza que uma classificação como planta é realmente pertencente a esta classe. Seu cálculo avalia a relevância da seleção, mas não observa a proporção de acertos em relação ao todo.

A métrica F-score, combina a característica de ambas as métricas, mitigando suas principais vulnerabilidades, portanto apenas abordagens que possuem elevada sensibilidade

e precisão podem gerar bons resultados. Esta métrica compreende o espaço de 0 a 1, sendo 1 uma classificação perfeita e 0 a ausência de verdadeiros positivos. Esta métrica se mostrou mais robusta a variação da pose, gerando resultados similares de desempenho independente da distância do objeto na cena.

Para cálculo das métricas de classificação, foi necessária a utilização de referências para determinar se a classificação dos píxeis das imagens foi correta ou não, portanto para cada imagem avaliada no estudo uma imagem verdade foi manualmente e cuidadosamente gerada por especialistas, para servir como padrão, representando a segmentação ideal da planta na cena.

Considerando que um dos possíveis propósitos para a segmentação das mudas de plantas é garantir o reconhecimento e rastreo deste objeto, um segundo indicador de desempenho foi utilizado, este avalia a distância entre os centros do objeto segmentado por dado algoritmo e sua respectiva referência. Esta distância é estipulada a partir da diferença em píxeis dos centros na direção x e y das imagens, ajustada em função do tamanho da diagonal da imagem. Gerando um resultado percentual de erro que não é influenciado pelo tamanho da imagem, sendo representado da seguinte forma:

$$\text{Erro distancia}(\%) = 100 \cdot \sqrt{\frac{\Delta x_p^2 + \Delta y_p^2}{\text{largura}_p^2 + \text{altura}_p^2}} \quad (3.5)$$

Com Δx_p^2 e Δy_p^2 a diferença em píxeis do centro do objeto segmentado em relação ao centro da referência nos eixos x e y da imagem.

3.3.2 Métricas de desempenho computacional

A avaliação de desempenho computacional foi realizada basicamente através da medição dos tempos de execução dos algoritmos. Para tanto foram implementados nos códigos contadores de tempo de alta precisão nas funções específicas associadas a cada abordagem, assim processamentos comuns a todas as abordagens como a captura da imagem, gravação da imagem de saída, comandos de interface e outros, não foram computados.

A contagem do tempo considera desta forma apenas os aspectos associados a abordagem, isto inclui as operações de conversão de modelos de cor, as manipulações e conversões de dados necessárias, ajustes de escala, operações de restauração de cores, operações de limiarização, classificação e demais processamentos necessários. Etapas de pré-processamento, como as abordagens de constância de cor, e de pós-processamento, como as operações morfológicas, foram monitoradas separadamente do processo de segmentação.

Para garantir maior precisão e confiança na estimativa de tempo de execução, o valor considerado de processamento foi calculado pela média de 100 processamentos consecutivos de cada abordagem, estando a unidade processadora na mesma condição

ambiente e submetida as mesmas atividades computacionais durante aquisição de todos os dados.

3.4 Análise de resultados

Devido à estrutura fatorial do experimento, a maior parte das análises fez uso das ferramentas e estratégias comuns a este tipo de abordagem. Os resultados foram em grande parte avaliados graficamente e ocasionalmente de forma analítica por meio de ferramentas estatísticas.

Na análise gráfica, todos os dados do experimento foram dispostos em um gráfico de forma a facilitar a análise prática dos resultados: o eixo Y contém as respostas e o X evidencia as condições de teste por meio de legendas dos devidos agrupamentos do experimento. Esta forma de agrupar os dados caracteriza o gráfico conhecido por *variability chart* ou *multi-vari charts*.

Para as análises quantitativas, os efeitos dos fatores e das interações entre os fatores foram calculados. O efeito consiste em um número que representa a mudança da variável resposta em função da mudança do nível do fator, isto é, ele evidencia a relação de causa e efeito entre o fator e a resposta do experimento. Seu cálculo é simples e baseia-se meramente na média da diferença entre a soma dos valores de todas as condições de teste em que o fator ou interação se encontra no nível um (+) com as condições de nível dois (−). Seu cálculo pode ser descrito da seguinte forma:

$$\text{Efeito} = \frac{\sum \text{valores no nível um} - \sum \text{valores no nível dois}}{\text{numero de observações}/2} \quad (3.6)$$

Após a realização do cálculo de todos os efeitos do experimento, ocasionalmente um gráfico de Pareto foi construído para facilitar a visualização comparativa dos efeitos, destacando desta forma os maiores contribuintes à mudança da variável resposta do experimento. Além disto, para assegurar a confiança nas observações realizadas pela análise gráfica, a análise de variância foi por vezes utilizada para demonstrar a significância estatística dos resultados.

3.5 Sistema de aquisição

Apesar das diferentes condições experimentais, o sistema e fluxo de dados utilizados no estudo são constantes e configuram as operações base da campanha experimental. Como descrito na seção de infraestrutura, as plantas foram montadas sobre bases e um dispositivo de posicionamento foi acoplado ao sistema de captura garantindo a cena e pose das imagens.

O sistema de captura é caracterizado pelo módulo embarcado Raspiberry Pi, juntamente com um dispositivo de captura (webcam ou raspicam) e uma bateria, assegurando portabilidade ao sistema e possibilitando sua utilização em ambientes abertos. Os comandos de captura por sua vez foram realizados através do acesso remoto ao sistema por uma conexão VNC(*Virtual Network Computing*) em rede local sem fio com o uso de um roteador portátil, permitindo a visualização da imagem da câmera e controle sobre o momento da captura (vide Figura 18). As imagens eram então salvas na memória do dispositivo móvel e coletadas posteriormente para análise.

Figura 18: Esquema do sistema de captura utilizado nos experimentos.

O software de captura, foi desenvolvido em Python, e seguiu o processo de aquisição que será utilizado na aplicação, visando elevada velocidade de captura e acesso individual as imagens para processamento. Desta forma, as amostras de imagens capturadas possuem alta correlação com as obtidas na prática. Além disto o programa permitiu uma configuração manual dos parâmetros de ambas as câmeras, possibilitando a calibração e ajuste de ganho de seus canais, assim como possibilitou desabilitar ou habilitar as funções de ajuste automático de branco e de luminosidade das câmeras.

As imagens capturadas caracterizaram as amostras dos experimentos. Estas foram submetidas as abordagens de pré-processamento ou de segmentação, gerando ao fim imagens binárias que foram exportadas, juntamente com seu tempo médio de processamento. Duas versões deste programa de segmentação foram desenvolvidas, uma em Python e outra no Wolfram Mathematica, sendo a versão em Python executada em ambos os processadores.

Essas imagens foram então avaliadas juntamente com sua respectiva imagem verdade, através de um programa no Mathematica gerando as respostas finais em funções das métricas de desempenho de segmentação e computacional descritas em seções anteriores, estes dados eram por fim agrupados em planilhas para análise. O diagrama da Figura 19, sumariza os processos descritos na seção.

Figura 19: Fluxograma genérico do fluxo de dados da captura até a obtenção dos resultados para os 5 experimentos da campanha experimental, com destaque aos softwares utilizados.

3.6 Campanha Experimental

A campanha experimental foi composta pela sequência de cinco experimentos planejados, os dois primeiros tiveram como objetivo, avaliar o sistema de medição e definir os fatores, níveis e demais condições experimentais para os experimentos subsequentes. Os outros três, foram responsáveis por promover as informações para a análise comparativa de desempenho das abordagens de segmentação, assim como avaliar a influência dos algoritmos de constância de cor. A Figura 20 em sequência resumi a campanha experimental e prove uma visão geral da mesma.

Figura 20: Resumo das etapas, objetivos e saídas dos experimentos da campanha experimental.

As seções em sequência irão detalhar as condições experimentais de cada um dos

cinco experimentos, sendo que um maior entendimento de suas configurações, só serão compreendidos com a interpretação dos resultados descritos na seção 4, devido a natureza investigativa sequencial da campanha experimental.

3.6.1 Experimento 1 - Análise inicial do sistema de medidas

O primeiro experimento consiste na primeira investida para verificação do sistema de medidas desenvolvido. O intuito foi primeiramente entender se as métricas de desempenho definidas para o estudo eram capazes de diferenciar as respostas dos fatores estudados e, em especial, verificar se o sistema era capaz de identificar diferença nas abordagens. Esta análise é crítica para o estudo, uma vez que a interpretação dos resultados dos experimentos posteriores se baseiam completamente nestas métricas.

O experimento foi estruturado como uma análise de componentes de variação, isto é, além da avaliação das variáveis respostas (métricas) para o estudo, alguns componentes selecionados foram investigados para entendimento de suas influências nas respostas. Desta forma pode-se observar quais variáveis são críticas para a resposta e, portanto, devem ser controladas ou estarem presentes nos demais estudos; e quais variáveis geram pouca influência e podem ser fixadas ou negligenciadas nos próximos experimentos.

Em outras palavras esta primeira investigação pretendeu dar maior entendimento ao problema de comparação de abordagens e juntamente avaliar condições e configurações que pudessem influenciar neste processo. A Tabela 5 abaixo dá uma visão geral dos componentes avaliados, e as condições a quais estes foram submetidos.

Tabela 5: Condições do Experimento 1

Constantes				
Ambiente	Interno			
Pose	Altura 400mm			
Sistema de captura	Rpi+Raspicam			
Variáveis	Condição 1	Condição 2	Condição 3	Condição 4
Objeto	Hortela	Marnjericão	Morango	Excess Green
Resolução	320x240	640x480	1280x960	
Processador	Rpi+OpenCV	PC+OpenCV	PC+WM	
Segmentação	Otsu	Hue Intervalo	Hue modificado	
Pós-processamento	Sem morfologia	Com morfologia		
Respostas	Métricas			
Desempenho Segmentação	Erro total(%)			
Desempenho Computacional	Tempo de processamento (ms)			

Este primeiro experimento foi realizado em ambiente interno, sob iluminação controlada, com pose constante e com os ajustes automáticos da câmera de branco e exposição desabilitados reduzindo as variações experimentais decorrentes da iluminação. O pós processamento morfológico desta e das demais investidas experimentais é constituído pelas operações abertura seguido de fechamento por um elemento estruturante quadrado de 3x3. Além disto, três repetições amostrais foram realizadas para cada condição, ou seja, três capturas consecutivas da cena. Ao fim foram obtidas 27 imagens distintas da cena; estas foram aplicadas em 4 abordagens de segmentação, duas condições morfológicas em três diferentes processadores, totalizaram 648 execuções, cada uma contendo os dados de tempo de processamento e erro total de segmentação.

Em relação as variáveis experimentais sua inclusão pretendia gerar a análise dos seguintes pontos:

- Influência das características das plantas no resultados;
- Impacto da resolução de captura nas métricas;
- Entendimento das relações de diferentes processadores e softwares para os resultados;
- Observar a representatividade das métricas para mensuração dos desempenhos;
- Verificar o ganho gerado pela operação morfológica no pós-processamento;

3.6.2 Experimento 2 - Análise complementar do sistema de medidas

Baseado nos resultados do primeiro experimento, e de forma a cobrir aspectos adicionais do sistema de medidas, o segundo experimento foi executado, com propósito a complementar a definição de parâmetros de teste e avaliação das métricas.

Uma das principais diferenças neste experimento foi a inclusão da pose de captura como variável, avaliando se a distância do objeto de interesse e a maior presença de fundo em relação a planta impactariam nos resultados. As primeiras análises mostraram que a métrica de desempenho de segmentação baseada pelo erro total, não era justa e sua sensibilidade era alterada em função da proporção de píxeis relevantes e fundo. Esta diferença era muito clara em casos de falha total de detecção, onde os valores de erro eram diferentes para cada condição, sendo muito menores para imagens mais distantes. Esta relação da métrica com a pose, configurou uma característica indesejada para este e demais experimentos, levando a reavaliação das métricas.

Como alternativa a métrica F-score foi elegida e sua associação com os resultados de desempenho se mostraram mais corretas e sem nenhuma tendência inicial em relação a pose; de forma que sua métrica foi considerada como variável resposta para ser avaliada como

Tabela 6: Condições do Experimento 2

Constantes	
Ambiente	Interno
Cena	Manjerição com detritos
Sistema de captura	Rpi

Variáveis	Condição 1	Condição 2	Condição 3	Condição 4
Segmentação	Otsu	Hue Intervalo	Hue Otsu	Excess Green
Iluminação	6800K	3000K		
Pós-processamento	Sem morfologia	Com morfologia		
Pose	Altura 400mm	Altura 800mm		
Câmera	Webcam	Raspicam		
Resolução	320x240	640x480		

Respostas	Métricas	
Desempenho Segmentação	F-score(%)	Erro distância(%)
Desempenho Computacional	Tempo de processamento (ms)	

parte do sistema de medidas. As demais condições do experimento podem ser observadas na Tabela 6 que segue:

Este experimento é o primeiro da campanha a apresentar uma estrutura fatorial em sua concepção, o componente associado as abordagens de segmentação representam blocos experimentais, já os demais componentes são fatores do experimento e estão condicionados em dois diferentes níveis e 3 repetições. Caracterizadas por capturas consecutivas da cena de cada uma das 32 condições experimentais gerada pelos 5 fatores analisados. Ao todo 48 imagens diferentes foram capturadas que ao serem submetidas as quatro abordagens de segmentação e as operações morfológicas, totalizaram 384 imagens binárias.

Esta estrutura permitiu a avaliação da contribuição dos fatores nas variáveis respostas, onde se pretendeu avaliar:

- O impacto da cromaticidade da fonte luminosa no desempenho de segmentação dos métodos;
- Verificar a influência da operação morfológica sob diferentes poses;
- A contribuição da pose nos resultados de desempenho;
- A diferença nos resultados em função do hardware de captura;
- Compreender a interação da resolução com a pose e seus impactos;

3.6.3 Experimento 3 - Comparativo das abordagens de segmentação

Com as contribuições dos experimentos anteriores, um maior entendimento do sistema de medidas e das condições experimentais adequadas foram adquiridos, dando início as análises comparativas das abordagens de segmentação. A partir desta etapa para garantir representatividade das conclusões com a aplicação, as condições experimentais foram aproximadas das condições reais.

As mudas utilizadas foram soja e milho, ambas em terra roxa, constituindo uma cena muito comum, especialmente no cenário agrícola nacional; detritos diversos foram também utilizados para geração de ruídos visuais e os experimentos foram executados em ambiente externo, sendo o grande foco do comparativo a análise da segmentação sob as condições adversas de iluminação existentes no ambiente externo.

Este experimento constitui a primeira etapa para a análise das melhores configurações de segmentação de plantas, neste apenas as abordagens de segmentação foram testadas, isto é, sem tratamentos de pré-processamento. As melhores respostas foram levadas para o próximo experimento onde foram avaliadas sob a aplicação das práticas de constância de cor. Esta divisão em duas etapas foi proposta pois a combinação de todas as abordagens de segmentação com os métodos de invariância luminosa para um único experimento, ocasionaria em um número muito grande de condições, o que sobre carregaria a operação, o processamento, e o volume de dados para a análise.

Ao todo foram comparadas neste experimento 26 abordagens, sendo estas as tentativas mais promissoras obtidas após cuidadosa análise de uma etapa de pré-seleção. Neste processo foram eliminadas as abordagens com claros sinais de falhas e inconsistências de segmentação ou com baixa discriminação entre planta e fundo. Além disto foram determinadas as estratégias mais eficientes de limiarização, assim como foram avaliadas as combinações entre canais que promoviam a maior separabilidade entre os elementos de interesse e o fundo.

Esta seleção teve fundamento na literatura, em especial o estudo de ([GARCÍA-MATEOS et al., 2015](#)), juntamente com a aplicação e avaliação prática dos espaços de cores, seus canais, combinações e métodos de classificação para um conjunto de 10 imagens de diferentes de plantas sob variadas condições de iluminação. Esta avaliação prévia, além de definir as combinações mais promissoras para a análise, estimulou a criação de algumas novas propostas de segmentação, geradas por combinações diferentes de canais e parâmetros, assim como novos espaços de cor e índices vegetativos. As abordagens finais e suas características estão sumarizadas na Tabela 7.

Nesta relação pode-se observar que além das abordagens mais convencionais, com origem descrita como *baseline*, a maior parte das estratégias estão fundamentadas na literatura por meio das relações que propiciam o maior destaque aos píxeis associados a

Tabela 7: Relação das abordagens selecionadas para o comparativo

ID	Abordagem	Modelo de cor	Limiarização	Origem
1	Otsu	Escala de cinza	Otsu	<i>Baseline</i>
2	Hue	HSV	Intervalo de 30 à 85 (255)	<i>Baseline</i>
3	Hue	HSV	Otsu	<i>Baseline</i>
4	Y - X	XYZ	Otsu	Literatura
5	a*	L*a*b*	Otsu	Literatura
6	b*-a*	L*a*b*	Otsu	Literatura
7	u*	L*u*v*	Fixo em 96 (255)	Literatura
8	v*-u*	L*u*v*	Otsu	Literatura
9	v*-1,4u*	L*u*v*	Otsu	Proposta
10	Cr	YCrCb	Otsu	Literatura
11	Cr + Cb	YCrCb	Otsu	Proposta
12	l3	l1,l2,l3	Otsu	Testes
13	l3 - l2	l1,l2,l3	Otsu	Testes
14	i3	i1,i2,i3	Otsu	Testes
15	V1	I,V1,V2	Fixo em 1 (255)	Testes
16	Cg	CrCgCb	Otsu	Proposta
17	ExG em CrCgCb	CrCgCb	Otsu	Proposta
18	Excess Green(ExG)	rgb	Otsu	Literatura
19	Excess Red(ExR)	rgb	Otsu	Literatura
20	ExG - ExR	rgb	Fixo em 1 (255)	Literatura
21	ExG em RGB	RGB	Otsu	Proposta
22	NDI	RGB	Fixo em 1 (255)	Literatura
23	NDI	RGB	Otsu	Literatura
24	NDI Modificado	RGB	Otsu	Literatura
25	F1 - F2	Invariante	Otsu	Literatura
26	F1 - F2	Invariante	Otsu	Proposta

planta. Entretanto algumas configurações apresentaram divergência da literatura, e seus parâmetros foram determinadas pelos resultados dos testes preliminares (testes). Já as abordagens cuja origem está destacada como proposta, foram baseadas em combinações inusitadas de canais e parâmetros por meio dos espaços de cor tradicionais; sendo definidos pela relação matemática e método de limiarização descritos na tabela. Entre estas combinações, uma investida baseada na formulação do espaço YCrCb, foi elegida pelos resultados promissores nos testes preliminares, gerando um espaço denominado de CrCgCb. Para sua concepção o canal acromático do espaço original (Y), foi substituído por um canal cromático adicional, associado com a cor verde (Cg) da seguinte forma:

$$Cg = 1,211.(G - Y) + 0.5 = -0.362R + 0.500G - 0.138B + 0.5 \quad (3.7)$$

Por fim, algumas propostas inspiradas no índice *Excess Green* também mostraram potencial, estas foram geradas através da relação original entre os canais para outros modelos de cor como RGB e CrCgCb, ao invés do convencional espaço rgb. Sendo sua

formulação expressa por:

$$\begin{aligned} \text{ExG em RGB} &= 2.G - R - B; \\ \text{ExG em CrCb} &= 2.Cg - Cr - Cb; \end{aligned} \quad (3.8)$$

Com intuito de investigar o desempenho e robustez das abordagens nas mais variadas condições de iluminação e suas interações, este conjunto de 26 abordagens foram avaliados em um experimento planejado fatorial completo. Com 3 fatores associados a iluminação e 1 associado a cromaticidade da planta, totalizando 16 condições experimentais, que com 5 repetições acarretaram em um grupo de 80 imagens. Esta estrutura foi aplicada em 26 blocos, associadas as abordagens, gerando ao fim 2080 imagens binárias resultando no mesmo número de dados para o tempo de processamento e desempenho de segmentação.

O experimento foi configurado como demonstra a Tabela 8 e uma breve justificativa de seus fatores e níveis segue em sequência:

Tabela 8: Condições do Experimento 3

Constantes		
Local	São Carlos	
Data	Novembro 2017	
Sistema de captura	Rpi+Raspicam	
Solo	Terra roxa+detritos	
Pose	400 mm de altura	
Pós-processamento	Sem Morfologia	
Resolução	640x480	
Variáveis	Condição 1	Condição 2
Abordagens de segmentação	26 Condições	
Cromaticidade da fonte	Dia (Luz Branca)	Tarde (Luz Amarela)
Planta	Muda de Soja	Muda de Milho
Incidência Luminosa	Direta	Difusa
Sombra	Ausência	Presença
Respostas	Métricas	
Desempenho Segmentação	F-score(%)	Erro distância(%)
Desempenho Computacional	Tempo de processamento(ms)	

- Para o fator cromaticidade da fonte luminosa (Sol), as cromaticidades mais comuns foram consideradas como a luz branca presente em maior na parte do dia, e a luz amarelada característica do períodos de início e fim de dia.
- A condição de incidência luminosa, considerou a iluminação direta de tempo aberto e sem nuvens, em contraste com a luz difusa proveniente de tempos nublados com Sol totalmente encoberto.

- Foi também manipulada a presença de sombra, ocorrência comum na aplicação, devida a posição relativa do sistema de captura em relação a fonte luminosa e cena, assim como demais oclusões naturais ocasionais. A condição de sombra foi simulada e controlada de forma a gerar sombra parcial no objeto de interesse, constituindo uma situação mais desafiadora para os métodos de segmentação e classificação, que a sombra total na cena.
- Por fim, interagindo com estas condições luminosas, as características superficiais das plantas e suas cromaticidades foram também avaliadas com o uso de duas diferentes espécies, mudas de milho e soja.

Devido a grande variação luminosa presente neste experimento, o ajuste automático de exposição foi habilitado, permitindo a câmera ajustar automaticamente o tempo de abertura do obturador para controlar a intensidade luminosa da captura. Configurações manuais e fixas para a câmera não seriam capazes de cobrir todo o espectro de configurações, gerando em diversas condições imagens saturadas. Em contraponto o ajuste automático de branco foi desabilitado e fixado, reduzindo a influência da câmera nas cores de captura da cena.

3.6.4 Experimento 4 - Avaliação das abordagens de constância de cor

Como já discutido, os resultados mais promissores do experimento anterior foram selecionados para esta etapa de avaliação das abordagens de constância de cor. Ao fim, das 26, apenas 10 abordagens foram elegidas e por sua vez combinadas com 12 diferentes tratativas de invariância, totalizando 130 estratégias de segmentação, estando inclusas as 10 respostas originais sem o pré-processamento de constância de cor.

Assim como na etapa anterior, os métodos de constância de cor, foram implementados, testados e ajustados previamente, selecionando apenas as tratativas de invariância promissoras para o experimento. Em situações de dúvidas sobre os melhores parâmetros para os algoritmos, duas diferentes configurações foram testadas, uma com mudanças mais expressivas, outra com compensações de iluminação mais amenas. As 12 tratativas de invariância selecionadas e seus parâmetros podem ser observados na Tabela 9.

As imagens base utilizadas para esta campanha foram as mesmas 80 obtidas no experimento anterior, assim para cada abordagem de constância de cor, um novo conjunto de imagens foi gerado a partir das cenas originais, obtendo-se ao fim 1040 cenas distintas. Simulando como seriam as imagens para a segmentação caso a tratativa de constância de cor fosse aplicada como uma etapa de pré-processamento. A combinação destes métodos com as dez abordagens de segmentação selecionadas, totalizaram 130 diferentes estratégias ao problema de identificação da planta, somando 10400 imagens binárias, com a mesma quantidade de dados de F-score.

Tabela 9: Relação dos métodos de constância de cor selecionados

ID	Método	Descritivo
0	Sem invariância	Imagem original, <i>baseline</i> para comparativo
1	Referência média	Ajuste pelo valor médio da esfera cinza
2	Referência máxima	Ajuste pelo valor máximo da esfera cinza
3	<i>GrayWorld</i>	Abordagem clássica
4	<i>GrayWorld</i> para média	Ajuste dos canais para o valor médio
5	<i>Scale By Max</i>	Abordagem clássica
6	<i>Scale By Max</i> com percentil 99,9%	Eliminação de 0,1% dos maiores valores
7	<i>Scale By Max</i> com percentil 97%	Eliminação de 3% dos maiores valores
8	MSRCR(<i>Gain/Offset</i>)	$G = 1, 5, b = 0, 25, \alpha = 125, \beta = 46, \sigma = 15/80/250$
9	MSRCR(<i>Simplest Color Balance</i>)	Valor de corte de 2%
10	MSRCR(<i>Exponential</i>)	Retorno exponencial e ajuste de intervalo
11	MSR(<i>Chromaticity Preservation 1</i>)	Valores de corte de 2% e 99,999%
12	MSR(<i>Chromaticity Preservation 2</i>)	Valores de corte de 2% e 98%

A Figura 21 demonstra o resultado dos algoritmos de invariância selecionados para 4 imagens originais em condições diferentes de iluminação.

As condições experimentais desta investida são consequentemente as mesmas da estrutura anterior, compartilhando seus objetivos e potenciais de análise. A diferença reside no simples aumento do número de abordagens pela combinação das estratégias de segmentação com as operações de pré-processamento, e na possibilidade de se avaliar a contribuição dos métodos de constância de cor na suposta melhoria da cena.

3.6.5 Experimento 5 - Comparativo das abordagens em condição crítica de iluminação

Para o último experimento, as cenas foram capturas ao anoitecer, nestas condições a intensidade luminosa é baixa e a cromaticidade da fonte luminosa se aproxima dos tons laranja e vermelho, representando uma situação bem desafiadora para a segmentação das plantas, especialmente pela aproximação da cor do objeto de interesse com o fundo. Sob estas circunstâncias as tratativas de constância de cor mostram-se ainda mais necessárias e promissoras, explorando nesta situação crítica o potencial destas abordagens em reduzir a variação da iluminação e assim aprimorar a robustez da segmentação.

Neste ultimo estudo as 10 segmentações selecionadas no experimento 3 foram novamente testadas e combinadas com as 12 tratativas de constância de cor cobertas no experimento anterior, gerando as mesmas 130 estratégias de segmentação (vide Figura 21), estas aplicadas nas 20 imagens da cena totalizaram 2600 dados provenientes da avaliação de suas imagens binárias. Esta condição representa um cenário mais desafiador para a segmentação e uma oportunidade maior para os métodos de constância de cor. Suas condições experimentais são similares ao do experimento anterior, diferindo na fixação dos fatores cromaticidade da fonte e incidência luminosa. A Tabela 10 sumariza o experimento.

Tabela 10: Condições do Experimento 5

Constantes		
Local	São Carlos	
Data	Novembro 2017	
Sistema de captura	Rpi + Raspicam	
Solo	Terra roxa + detritos	
Pose	400 mm de altura	
Pós-processamento	Sem Morfologia	
Resolução	640x480	
Cromaticidade da fonte	Anoitecer (Luz Alaranjada)	
Incidencia Luminosa	Direta	
Variáveis	Condição 1	Condição 2
Abordagens de segmentação	10 Condições	
Métodos de invariância	12 Condições + Original	
Planta	Muda de Soja	Muda de Milho
Sombra	Ausência	Presença
Respostas	Métricas	
Desempenho Segmentação	F-score(%)	Erro Distância(%)

Este experimento final teve como objetivo, avaliar a influência da iluminação em uma condição crítica, promover uma reavaliação do impacto dos métodos de constância de cor em um cenário mais desafiador e realizar um novo comparativo das estratégias elencadas.

Com a sequência experimental explicada nesta seção, o estudo teve o objetivo de realizar uma análise do sistema de medidas e definir fatores experimentais e métricas justas para serem aplicadas em experimentos comparativos que avaliassem diferentes abordagens de segmentação e pré-processamentos para as mais variadas condições de iluminação. Os resultados destas investidas serão cobertos em detalhe na seção 4 em sequência.

Figura 21: Demonstrativo das abordagens de constância de cor

4 RESULTADOS

Esta seção é composta pelos resultados consolidados da sequência experimental descrita nas seções anteriores, os experimentos serão avaliados e discutidos individualmente, assim como as devidas ressalvas das contribuições entre experimentos. Ao fim, considerações práticas dos resultados e recomendações para o problema de segmentação em ambiente externo agrícola serão fornecidas. Esta seção limita-se a análise dos resultados e suas reflexões sobre as respostas e condições experimentais, para maiores informações das configurações dos experimentos e suas justificativas, recomenda-se ao leitor revisitar a seção 3.

4.1 Resultados do experimento 1

O primeiro experimento, com o intuito de avaliar o sistema de medidas, fez uso de uma configuração experimental de análise de componentes de variação, com três repetições. Iniciando pelos resultados de tempo, seus valores estão dispostos no gráfico *variability chart* para visualização do desempenho geral e análise gráfica do experimento (vide Figura 22).

Figura 22: *Variability Chart* dos tempos de processamento em milissegundos

Assim como os demais gráficos de *variability chart* descritos nesta seção, os pontos em azul representam os dados, a escala a esquerda demonstram os valores na unidade descrita pela legenda, as divisões e rótulos no eixo horizontal, delimitam e identificam os grupos dos dados, e as linhas horizontais verdes em meio aos dados, representam a média de um determinado agrupamento. No caso do gráfico acima, as linhas verdes representam as médias no nível do objeto, ou seja, a média de todos os pontos dentro do agrupamento da espécie da planta. Sendo os agrupamentos A1 à A4 associados respectivamente as abordagens de segmentação da condição 1 à 4 da Tabela 5.

Observa-se inicialmente que existe uma grande variação dos tempos de processamento, os dados compreenderam valores de menos de 1ms até valores maiores que 1s.

Diversos componentes geraram alteração nos resultados de tempo demonstrando sensibilidade do sistema de medida; as repetições mostraram valores muito próximos em cada condição experimental, sendo sua variação consideravelmente menor que as variabilidades encontradas no sistema. O desvio padrão estimado para a medida de tempo neste experimento foi de 0,108 ms, demonstrando alta precisão para o experimento sob qual foi submetido. Entretanto a ocorrência de alguns poucos pontos espúrios, demonstra que o processamento não é consistente o suficiente e que um aumento do número de repetições poderia beneficiar a métrica e consequentemente as conclusões acerca destes resultados.

Em sequência nota-se que o principal contribuidor para a diferença dos tempos computacionais foram os processadores, com claro destaque de desempenho do computador com OpenCV e para os piores resultados o processamento realizado no módulo embarcado Raspberry Pi. Pela verificação das médias constata-se também que dentro de um mesmo processamento o objeto não gerou impacto significativo no tempo, mostrando indícios da independência da cena ao custo computacional. Estas observações gráficas podem também ser constatadas na Tabela 11.

Tabela 11: Comparativo dos tempos de processamento (ms)

		Processador			Média
		PC	Rpi	WM	
Objeto	Hortelã	5,65	174,58	48,05	76,09
	Manjeriçã	5,51	176,86	48,04	76,80
	Morango	5,53	165,8	48,38	73,24
	Média	5,56	172,41	48,16	75,38

Além disto nota-se que outros componentes são responsáveis pela variação dos resultados. Para elucidar melhor a contribuição das fontes de variação, o gráfico da Figura 23, demonstra os resultados de tempo normalizados pelo valor médio de cada processador.

Figura 23: *Variability Chart* dos tempos de processamento normalizados

Para estes gráficos, os valores médios (linhas horizontais verdes) estão associados as abordagens (A1 até A4), destacando a clara diferença que estes geram no processamento, portanto a abordagem *excess green* foi que mais consumiu tempo, seguida da HSV

modificado, HSV apenas e como esperado a operação de menor tempo foi a limiarização direta por Otsu. Além disto nota-se que com o ajuste de escala, a reprodutibilidade de tempo entre os processamentos é alta, as respostas são suficientemente similares de forma que as inferências e estimativas sobre as abordagens e resoluções possam ser feitas sob qualquer processamento, tornando razoável a utilização de processadores mais poderosos para prototipagem ou avaliações preliminares do desempenho de abordagens em módulos embarcados.

Vale notar, contudo, que esta inferência não é absoluta, existem diferenças de processamento, e os tempos reais só podem ser obtidos no processador alvo, como fica evidente ao se observar os impactos das operações morfológicas entre os processamentos. A sua aplicação aumenta consistentemente o custo computacional para todas as condições, mas sua contribuição para o tempo dos algoritmos foi diferente para cada processador, como pode ser observado na Tabela 12.

Tabela 12: Aumento proporcional do processamento pelo uso das operações morfológicas

Resolução	PC	Rpi	WM
1280x960	13,25%	87,43%	36,64%
640x480	7,03%	82,45%	47,50%
320x240	8,64%	82,63%	113,11%
Média	12,00%	86,18%	42,19%

Esta diferença se dá provavelmente pelas diferenças de arquiteturas, pelos tamanhos variados de memórias, e no caso do Mathematica, pela forma em que suas variáveis são processadas. Como observação importante nota-se que este tipo de operação, apesar de relativamente trivial para o computador pessoal (aumento de apenas 13%), apresenta um grande desafio computacional, para o módulo embarcado, aumentando em mais 80% o custo computacional da operação de segmentação. No Mathematica para pequenas imagens nota-se um comportamento anômalo, com um aumento proporcional excessivo do custo computacional, talvez em função de algum *overhead* associado a função.

Por estar caracterizada como etapa de pós-processamento a operação morfológica não depende da abordagem ou cena submetidas, sua operação depende apenas do tamanho do elemento estruturante e da quantidade de píxeis da imagem, ou seja, para cada resolução seu acréscimo de tempo será aproximadamente o mesmo sendo estes observados na Tabela 13.

Tabela 13: Acrescimo de tempo devido operação morfológica (ms)

Resolução	PC	Rpi	WM
1280x960	1,64	235,93	33,19
640x480	0,18	60,89	11,1
320x240	0,07	14,7	6,04
Média	0,63	103,84	16,78

Com este resultado já podemos observar a influência da resolução nos tempos de processamento, sendo que um comportamento análogo é esperado para os demais processamentos realizados nas imagens. Para visualização da influência da resolução nas respostas, o gráfico da Figura 24, contém apenas os resultados do processador Raspberry Pi, com as médias associadas ao tamanho da imagem, descritas pelas letras G,M e P, representando as imagens nas resoluções grande, média e pequena respectivamente.

Figura 24: *Variability Chart* do Raspberry Pi para os tempos de processamento (ms)

Além das demais observações realizadas até o momento nota-se neste gráfico o claro impacto do tamanho das imagens no custo computacional, sendo este maior quanto maior o número de píxeis. As condições de resolução apresentam uma relação de 4 vezes o número de píxeis entre si, esta proporção é notada nos tempos médios das operações, especialmente no Raspberry Pi, mas diferenças nos processamentos, pela forma como eles lidam volumes diferentes de dados, geram diferenças consideráveis nestas relações, como pode ser observada na Tabela 14.

Tabela 14: Comparativo de resoluções e processamentos no tempo computacional (ms)

Resolução	Tempo médio total			Relação de velocidade em relação ao Rpi			Relação de tempo em função da menor imagem		
	PC	Rpi	WM	PC	Rpi	WM	PC	Rpi	WM
1280x960	13,21	387,81	107,18	29,36	1,00	3,62	15,54	15,43	12,82
640x480	2,65	104,3	28,92	39,36	1,00	3,61	3,12	4,15	3,46
320x240	0,85	25,14	8,36	29,58	1,00	3,01	1,00	1,00	1,00
Média	5,568	172,415	48,154	30,97	1,00	3,58			

Esta Tabela também estabelece uma referência para a relação dos tempos computacionais entre os processadores, podendo servir como fator de escalabilidade de tempo para prototipagem e testes de algoritmo entre as diferentes plataformas. Esta relação de velocidade depende da resolução da imagem, mas em média pode-se esperar tempos computacionais aproximadamente 30 vezes maior no módulo embarcado em relação ao computador *high-end* e cerca de 3,5 vezes maior em relação a linguagem de alto nível Wolfram Mathematica neste mesmo computador.

Já em relação ao desempenho de segmentação para avaliação geral do experimento, pode-se observar os valores dispostos no gráfico *variability chart* da Figura 25

Figura 25: *Variability Chart* do erro total de segmentação (%)

Novamente observa-se grande variação nos valores, com grande destaque para a influência das abordagens na resposta, com dois níveis distintos. A abordagem 1 (Otsu) com valores muito maiores de erros, e as demais abordagens baseadas em segmentações por cor com valores próximos a zero, evidenciando o potencial desta característica ao problema de segmentação. Em relação ao sistema de medidas, a variação da repetição é pequena em relação a influência dos demais componentes avaliados, mostrando precisão das métricas para comparativo das abordagens.

Indícios observados neste experimento com resultados mais expressivos nas demais investidas, demonstram que a estabilidade e consistência da medição de imagens consecutivas está intimamente relacionada com as abordagens, permitindo a associação do desvio das repetições com a robustez da solução de segmentação. Pode-se constatar que para alguns métodos diferenças imperceptíveis nas imagens e na iluminação podem ter impacto considerável na resposta de segmentação, como é observado na Figura 26

Uma característica importante a ser observada é a alta reprodutibilidade das respostas entre os processadores. Como esperado os resultados para o PC e Rpi foram idênticos por fazerem uso do mesmo algoritmo desenvolvido em Python com OpenCV, mas mesmo para o programa executado no Wolfram Mathematica as divergências foram pequenas, menores que 2%, evidenciando o potencial desta linguagem de alto nível como base de investigação de abordagens. Esta divergência pode em parte ser explicada pela diferença no formato dos dados utilizados, a resolução dos pixels das imagens utilizadas no OpenCV foram limitados a valores inteiros em 8 bits enquanto o Mathematica, converte os valores da imagens a um intervalo real de 0 a 1, o que através dos cálculos, propagação de erros e característica não linear de algumas transformações pode levar a pequenas diferenças nos resultados finais.

As médias do gráfico da Figura 25, foram estabelecida no nível do objeto e demonstram que para o desempenho de segmentação a cromaticidade e textura da planta tem

Figura 26: Exemplo de variações de segmentação entre capturas consecutivas

grande influência no resultado, devendo ser um ponto de atenção para todos os demais estudos. Este componente claramente impacta as respostas com limiarização direta por Otsu, entretanto o gráfico da Figura 27, detalha a resposta dos métodos baseados por cor e demonstra que seu impacto é grande também para as estas abordagens.

Figura 27: *Variability Chart* do erro total de segmentação (%) para as abordagens baseadas em cor

Em todos os casos o manjeriço, planta com o tom de verde mais claro, apresenta os melhores resultados de segmentação, seguido pela hortelã, e com os piores resultados, tem-se a muda de morango, com as folhas mais escuras deste experimento. Reafirma-se neste gráfico a capacidade das medidas de diferenciar as variáveis do experimento. As médias estão associadas as abordagens e demonstram graficamente que sua influência na resposta é significativa, os métodos 2 e 3 (HSV e HSV modificado), por se basearem no mesmo espaço de cor, apresentaram respostas similares, com ligeira vantagem ao último. Já a abordagem 4 (*Excess Green*) gerou os piores resultados de segmentação por cor.

É importante destacar que apesar da grande influência do objeto de interesse nas respostas de segmentação, manteve-se a consistência nas conclusões acerca das abordagens de segmentação, ou seja, os melhores e piores métodos se mantiveram apesar da planta sob análise. Essa informação pode ser utilizada para sugerir a reprodutibilidade dos resultados para diferentes plantas, expandindo o potencial das conclusões. Os resultados gráficos discutidos podem ser observados também na Tabela 15.

Tabela 15: Comparativo do erro de segmentação(%)

		Abordagem			Média
		HSV	HSV Modificado	Excess Green	
Objeto	Hortelã	1,02	0,95	1,96	1,31
	Manjeriço	0,44	0,43	1,13	0,67
	Morango	2,26	2,20	4,39	2,95
	Média	1,24	1,19	2,49	1,64

Em relação a morfologia a sua aplicação demonstra redução do erro total em todas as aplicações, gerando melhoras consistentes aos resultados. Entretanto a melhora não foi tão significativa quanto esperado, especialmente em situações em que o erro já está reduzido pela aplicação de abordagens direcionadas a segmentação por cor. A redução média do erro total com a aplicação da morfologia foi de 0,706%, sendo ainda menor ao se considerar apenas as abordagens por cor, com uma diferença de 0,059%, representando uma melhoria proporcional de aproximadamente 3%.

A resolução por sua vez representa um impacto mais significativo, sendo responsável pela maior parte da variação dentro de uma mesma abordagem. Nas abordagens baseadas por cor, nota-se uma tendência de redução do erro com o aumento do tamanho da imagem, as médias foram da maior para a menor resolução respectivamente: 1,17%, 1,73% e 2,19%. Esta diferença pode ser explicada por dois efeitos, notou-se que determinadas transformações, apresentam ruídos e classificações incorretas nos contornos do objeto, assim quanto maior a resolução menor a proporção de pixels de transição e consequentemente menor o erro. Outra possibilidade é o aumento dos erros de classificação pela pioria de qualidade da imagem referência, com a redução da resolução o processo manual de determinação dos pixels de planta se torna mais difícil e os eventuais erros na imagem verdade tem maior impacto nas métricas pelo menor número de pixels.

Ao fim, combinando as respostas de desempenho computacional e de segmentação, tem-se com este experimento as seguintes conclusões:

- As métricas foram capazes de detectar diferenças entre as demais variáveis experimentais, mostrando grande potencial no sistema de medidas proposto, entretanto a variação eventual das respostas das abordagens a imagens consecutivas, prevê que

utilizar mais repetições pode fornecer estimativas melhores de valor médio, além de prover informações importantes da estabilidade das soluções propostas.

- Para o custo computacional, os processadores tem grande influência, mas com ajustes de escala pode-se observar reprodutibilidade. Aspectos da cena, como o objeto de interesse, não parecem mudar o tempo das respostas.
- A resolução impacta diretamente e significativamente nos tempos de processamento, sendo proporcionais a quantidade de pixels. Entretanto o aumento do processamento é acompanhado por uma melhora significativa de desempenho de segmentação, estabelecendo uma relação de custo benefício.
- A operação morfológica gerou melhorias em todas as respostas, mas seu alto custo computacional, especialmente no módulo embarcado, desencoraja sua aplicação devido aos ganhos de segmentação pouco expressivos.
- As características da muda impactam na resposta de segmentação e devem ser considerados em análises de desempenho.
- As abordagens tem como esperado grande impacto na segmentação, neste experimento as abordagens baseadas no espaço HSV mostram os melhores resultados, além disto, as respostas dos métodos mostraram reprodutibilidade entre as diferentes mudas.
- Com as devidas ressalvas é possível fazer uso de ferramentas e softwares de alto nível como o Mathematica para prototipagem e teste de abordagens, pela alta correlação de ambos os resultados com o PC e módulo embarcado (Rpi).

4.2 Resultados do experimento 2

O experimento de número dois, traz avanços ainda maiores na avaliação e definição das métricas, é o primeiro experimento da sequência com estrutura fatorial de experimentos planejados e como já explanado, introduziu a métrica de segmentação F-score, uma medida mais apropriada por se mostrar menos susceptível as condições da cena que o erro total.

Iniciando novamente a análise pelos aspectos computacionais tem-se o seguinte gráfico da Figura 28, neste os dados estão dispostos de forma que os menores agrupamentos estão associados a câmera, pose e iluminação respectivamente. As médias (linhas verdes) por sua vez representam o valor médio no nível da resolução.

Observa-se com este gráfico que as conclusões do primeiro experimento são consistentes, assim como no anterior, os fatores decisivos para o tempo de processamento foram, a interação entre abordagem, resolução e morfologia. Novamente o método *Excess Green* é o que mais consome tempo, os métodos com HSV tem tempos similares e o Otsu segue com o menor tempo de processamento. Além disto os aspectos da cena, neste caso associado

Figura 28: *Variability Chart* do tempo de processamento(ms) para o experimento 2

a iluminação, distância do objeto na cena e ao dispositivo de captura permanecem sem impacto nos tempos.

Nota-se com esta organização que a variação entre fotos na mesma configuração é muito pequena, o desvio padrão estimado de medidas para o Raspiberry Pi foi de apenas 0,34 ms constituindo uma elevada precisão para o sistema. Este fator aliado a consistência dos dados e a boa discriminação do sistema, demonstram que a métrica para desempenho computacional se mostra apta para avaliação das abordagens de segmentação.

Uma análise de efeitos foi realizada para abordagem referência de segmentação (HSV) por intervalo e seus resultados confirmaram a análise gráfica, que a maior parte da variação gerada dentro da abordagem é consequência da morfologia (39,7%) , do tamanho da imagem (35,8%) e da iteração de ambos (23,6%). A Tabela 16 formada pelas médias de todas as abordagens também ilustra esta influência.

Tabela 16: Comparativo dos tempos médios de segmentação (ms)

		Morfologia		Média
		Com	Sem	
Resolução	640x480	108,40	55,14	81,77
	320x240	28,42	14,86	21,64
	Média	68,41	35,00	51,71

Antes de iniciar a análise do desempenho de segmentação, vale a ressalva de que para reduzir o volume de dados, apenas uma muda foi utilizada, o solo simulou uma condição de alto ruído, com a presença de detritos, simulando uma condição mais próxima da aplicação. A iluminação foi estabelecida como fator sendo manipulado entre a luz branca e amarela. O gráfico 29, fornece visão geral do experimento, sendo o fator câmera descrito pelas letras R e W (Raspicam e Webcam) e as poses pelo valor da distância ao objeto (400 e 800mm), com as médias deste fator descritas em verde.

Observa-se que os fatores experimentais, foram capazes de gerar grande variação de respostas, demonstrando sua significância para o processo de segmentação, resultados quase

Figura 29: *Variability Chart* do F-score para análise de desempenho de segmentação

perfeitos foram gerados assim como falhas totais na identificação do objeto. Nota-se que para cada abordagem o comportamento dos fatores foram muito diferentes, mostrando forte interação dos blocos com os fatores experimentais, ressaltando a importância e impacto que a escolha do método adequado têm na segmentação da planta. A repetição foi no geral consistente e apresentou baixa variação, entretanto em condições experimentais mais instáveis os valores apresentavam grande diferença mesmo entre imagens sequenciais, revelando falta de robustez e baixa separabilidade da estratégia.

O fator da pose é um componente que se destaca pela clara tendência demonstrada independente da abordagem, os resultados foram em geral piores com a distância maior do objeto na cena. Nota-se que houveram condições que sua influência foi reduzida, como a exemplo os resultados do HSV com Otsu em luz amarela e HSV intervalo em luz branca, mostrando que sob condições ideais a métrica é robusta e se aproxima de um mesmo valor de desempenho. A diferença ocorre pois em caso de ruídos e falhas a pose mais distante fica mais exposta a estes erros penalizando com mais intensidade a métrica, em outras palavras, a pose define o grau de sensibilidade da métrica aos ruídos associados ao fundo, pois seu cálculo considera estas proporções. Em contraponto a pose mais próxima, garante uma melhor medição das métricas associadas ao objeto além de assegurar a criação de uma imagem verdade mais correta.

Outro fator extremamente crítico foi a iluminação, que apareceu na análise de efeitos como o fator mais significativo para todas as abordagens baseadas por cor, diferindo apenas para a abordagem Otsu, cujo fator mais significativo foi a pose já discutida. É interessante observar que não existe um sentido preferencial para os valores, para cada abordagem o resultado de segmentação foi impactado de uma forma diferente com a iluminação. As duas últimas abordagens mostraram resultados melhores sob a luz amarela, e a abordagem HSV com intervalo, a mesma utilizada no experimento 1 e mantendo a consistência dos resultados, apresentou os melhores valores na iluminação branca. Este resultado já fornece fortes indícios do impacto das condições de iluminação nas abordagens de segmentação por

cor, e reforça a necessidade de se estudar suas influências nas estratégias de segmentação.

Em relação a morfologia, novamente houve melhora no desempenho das abordagens, possuindo sempre efeito positivo, mas seu impacto além de previsível não foi tão significativo frente aos custos computacionais que foram também altos. Já para a câmera pode-se observar que houveram divergências de resultados, e muitas vezes apareceu sozinho ou em interação com a pose como fator significativo na análise de efeitos. Entretanto pode-se observar que seu efeito foi mais intenso em situações em que a abordagem e as condições da imagem estavam próximas de condições de corte sensíveis, onde pequenas variações da cena, levavam a resultados de segmentação significantemente diferentes, nestas condições de instabilidade, as pequenas variações do sensor e também a imperfeição do procedimento de calibração da câmera, se tornam significativas. A exemplo pode-se verificar os resultados da iluminação amarela na abordagem HSV com intervalo, pequenas variações de tonalidade jogaram os valores associados a planta dentro ou fora do intervalo, gerando repostas muito diferentes.

Na condição oposta, em situações mais estáveis, a influência da câmera foi muito pequena; é portanto importante que os métodos propostos assegurem estabilidade e robustez de forma a garantir a reprodutibilidade das respostas e expandir as conclusões para demais hardwares de captura. De maneira geral a Raspicam obteve melhores resultados em luz branca, enquanto a webcam apresentou na luz amarela. Contudo para aproximar os demais experimentos da aplicação, o comparativo foi realizado exclusivamente com a Raspicam.

Em todas as análises se observou que a resolução, não foi o fator mais significativo, mostrando que apesar da perda de detalhes a resolução mais baixa tem ainda grande potencial discriminativo. Entretanto, seguindo inclusive as observações do primeiro experimento, os melhores resultados foram predominantemente encontrados nas imagens de maior resolução, isto pode novamente estar associado a diferença de precisão dos cálculos, nas influências das áreas de transição e na dificuldade de se gerar a referência para as imagens menores. De forma a garantir maior assertividade nos resultados de segmentação para o comparativo foi padronizado a resolução média de 640x480.

As abordagens mostraram comportamentos muito distintos sob os fatores testados, em especial as condições de iluminação, nenhum método deste experimento mostrou bons resultados em todas as condições, mas para situações específicas algumas abordagens tiveram destaque no desempenho e consistência em relação as outras. Os resultados observados reafirmam a necessidade e potencial de se avaliar diferentes metodologias e abordagens de invariância luminosa para o desafio de segmentação, observando também as condições de sucesso e fracasso das mesmas. A Tabela 17, mostra os resultados médios das abordagens ilustrando as discussões retratadas, com o destaque para os melhores resultados.

Este experimento, consolidou a análise do sistema de medidas e configurou as

Tabela 17: Resultado F-score médio das abordagens sob diferente iluminações

		Iluminação		Média
		Luz Branca	Luz Amarela	
Abordagem	Otsu	26,97	28,86	27,91
	HSV Intervalo	84,70	35,57	60,14
	HSV + Otsu	74,87	91,41	83,14
	Excess Green	67,63	91,57	79,60
	Média	63,54	61,85	62,70

condições dos experimentos comparativos, pode-se destacar por sua análise as seguintes conclusões:

- O sistema de medida baseado no F-score se mostrou consistente e preciso, sendo capaz de diferenciar e comparar os diversos componentes experimentais, em especial a resposta das estratégias de segmentação. Entretanto de forma a capturar a variação e observar a robustez das abordagens, é recomendado aumentar o número de repetições, principalmente em ambientes com menor controle das condições experimentais.
- É de suma importância a fixação e controle da pose para os experimentos comparativos; a condição mais distante pode fornecer maiores informações sobre a robustez das abordagens, devido a maior sensibilidade da métrica aos ruídos do fundo, mas o aumento da dificuldade na geração da imagem verdade e a redução proporcional dos pixels associados a planta diminuem a resolução e rigor experimental, características estas, importantes para um comparativo extenso como o proposto.
- Apesar de tratar-se de uma condição simulada, o experimento e métricas conseguiram gerar e capturar a variação que a iluminação causa no processo de segmentação.
- Os ganhos da operação morfológica são consistentes, mas não são tão significativos quanto o aumento do custo computacional, sua utilização é recomendada apenas em caso de disponibilidade de processamento.
- As câmeras e procedimentos de calibração possuem diferenças inerentes que geram influência expressiva nos resultados em situações instáveis de segmentação. Para abordagens e condições mais robustas a diferença não se mostra significativa; evidenciando a importância de soluções robustas de segmentação.
- A resolução apresentou pouca influência nos resultados de desempenho, e apesar da melhora de precisão com o uso de resoluções maiores, quando necessário, pode-se considerar a redução do tamanho da imagem para alívio de custo computacional.
- Por fim, o experimento evidenciou que as abordagens interagem com a iluminação de formas distintas; e que portanto, o planejamento de experimentos com fatores

associados a este aspecto podem fornecer um melhor entendimento das capacidades das abordagens, justificando as seguintes investidas experimentais.

4.3 Resultados do experimento 3

Inicia-se agora a análise comparativa das abordagens, nesta primeira investida apenas os métodos de segmentação sem as operações de pré ou pós processamento são avaliados. Dos demais experimentos tem-se que os fatores de cena não tem influência nos resultados de tempo. Como todos os fatores testados tem ligação apenas com a composição da imagem, os únicos componentes influentes para o custo computacional são as abordagens. Portanto para a análise de tempo os agrupamentos foram ignorados, e os dados foram associados apenas as abordagens, constituindo o gráfico da Figura 30 e as análises subsequentes.

Figura 30: Tempo de processamento(ms) para o experimento 3 agrupado por abordagem

Devido o agrupamento utilizado, para cada abordagem obteve-se 80 observações do tempo de processamento, cada uma formada pela média de 100 execuções consecutivas, constituindo uma boa estimativa dos custos computacionais das abordagens. Este volume considerável de réplicas é importante pois notam-se variações consideráveis no processamento ao longo das avaliações, sendo os efeitos mais aparentes quanto maior a duração das abordagens, além disto, um ponto espúrio ocorre na ultima abordagem, mas seu efeito é minimizado pelo volume de dados. Ao fim a métrica se demonstra relativamente consistente e com elevada precisão para capturar as distinções entre abordagens, consolidando a Tabela comparativa 18 organizada em ordem crescente de tempo.

Observa-se na tabela uma grande gama de resultados, o Otsu por ser a operação mais simples e direta apresenta como esperado o menor valor de tempo. Seu resultado é utilizado também como fator de ajuste para geração uma medida adimensional de tempo, como observado na ultima coluna da tabela. Expandindo assim o uso dos dados para estimar o custo computacional das abordagens em outros processadores. O tempo de processamento vai sendo incrementado em cada abordagem até um valor máximo de 850ms nas abordagens associadas ao espaço de cor invariante a iluminação. Esta é particularmente

Tabela 18: Comparativo de tempo de processamento (ms) entre abordagens de segmentação

ID	Abordagem	Média	Desvio Padrão	Máximo	Relação com Otsu
1	OTSU	10,7	0,7	12,9	1,0
10	YCrCb (Cr)	22,6	0,8	24,4	2,1
2	HSV (Intervalo)	23,9	1,2	26,0	2,2
3	HSV (H)	25,8	1,1	27,5	2,4
5	Lab (a*)	28,7	5,7	53,7	2,7
11	YCrCb (Cr +Cb)	41,7	1,9	46,0	3,9
4	XYZ (Y - X)	50,3	2,6	56,1	4,7
21	Excess Green em RGB	54,5	3,1	62,0	5,1
6	Lab (b*-a*)	60,2	2,2	65,0	5,6
14	i1,i2,i3 (i3)	70,5	3,5	78,7	6,6
7	Luv (u* - manual)	85,2	0,6	86,8	8,0
16	CrCgCb (Cg)	85,5	3,5	95,4	8,0
22	NDI (manual)	98,8	4,1	110,4	9,3
23	NDI	103,0	4,3	114,1	9,6
24	NDI Modificado	103,9	4,2	115,3	9,7
15	I,V1,V2 (V1 - manual)	111,8	5,3	125,4	10,5
8	Luv (v*-u*)	118,4	2,2	123,9	11,1
17	CrCgCb (Excess Green)	134,0	6,5	150,4	12,6
9	Luv (v*- 1,4u*)	174,2	5,2	186,3	16,3
18	Excess Green	207,7	8,6	232,4	19,5
19	Excess Red	213,4	10,3	257,9	20,0
20	Excess Green minus Excess Red	214,1	9,6	240,3	20,1
12	l1,l2,l3 (I3)	493,8	26,3	557,3	46,3
13	l1,l2,l3 (I3 - I2)	543,0	29,6	615,3	50,9
26	Invariante a iluminação1 (F1-F2)	792,8	34,0	850,3	74,3
25	Invariante a iluminação2 (F1-F2)	796,1	18,8	844,9	74,6

exigente, pois utiliza diversas operações logarítmicas, que além de relativamente custosas, requer que os dados sejam convertidos para números reais.

Em via de regra observou-se que quanto maior o tamanho dos dados utilizados, mais custosa eram as operações matemáticas e consequentemente maior o tempo total de processamento da abordagem. Sempre que possível as conversões de dados foram evitadas nos programas, mas para determinadas conversões de espaço de cor, os dados originais de inteiros em 8 bits, não eram suficientes e tinham de ser alterados; nestas situações os dados eram convertidos para os formatos de menor impacto. Operações de divisões e multiplicações com números fracionados aumentaram consideravelmente o processamento, principalmente se as conversões geravam números negativos levando a um aumento ainda maior do tamanho dos dados. Operações exponenciais e logarítmicas como já discutidas geravam impactos ainda maiores no custo computacional.

Nota-se também que as abordagens apresentam diferentes consistências nos tempos computacionais, e que apesar de uma tendência geral e esperada de aumento do desvio

com o aumento do valor médio, algumas abordagens se destacam pela robustez e baixa variação das respostas, como a exemplo as abordagens baseadas no espaços $L^*u^*v^*$ e YCrCb. Estas características podem ser importantes em aplicações críticas ou em situações em que o processamento está muito carregado. Outras discussões acerca do tempo ainda serão realizadas mas em conjunto com os resultados de desempenho de segmentação.

Pelo grande volume de dados um gráfico completo com todos os agrupamentos e suas respectivas análises práticas torna-se um processo muito e pouco eficiente. Desta forma os dados foram agrupados e avaliados em função dos seus resultados gerais de segmentação. Esta organização dos dados simplifica o destaque das abordagens mais promissoras, observando de forma geral a robustez das respostas sob as condições de iluminação. Estas são então, em um segundo momento, analisadas em profundidade com a observação do efeitos e características particulares das soluções. O gráfico 31 retrata os dados do F-score, divididos por abordagens.

Figura 31: F-score(%) do experimento 3 agrupado por abordagem

Nota-se que em geral os resultados foram bons, diversas abordagens mostraram altos valores de F-score, alguns muito próximos da segmentação referência, mostrando a eficiência do processo de pré-seleção. Entretanto apesar de valores médios relativamente altos, muitas abordagens apresentaram grande variação nas respostas, mostrando falta de robustez as variadas condições de iluminação testadas. Algumas falhas foram muito significativas, reduzindo as respostas a valores inaceitáveis de segmentação, que em aplicação acarretariam a erros e falhas.

Algumas abordagens baseadas na literatura mostraram resultados gerais muito ruins de segmentação, apresentando resultados aceitáveis apenas em condições muito favoráveis. Como é o caso do NDI modificado, o *Excess Red* e o já esperado Otsu, que está presente no experimento para servir de base comparativa, como a aplicação mais básica de segmentação; caracterizando uma condição de ausência de esforços para destaque da planta.

Em contraponto alguns métodos mostraram alta eficiência de segmentação e elevada consistência, mantendo o F-score alto em todas as condições de iluminação. A Tabela 19 ordenada em função do F-score, resume o desempenho de segmentação das abordagens,

contendo além desta métrica, seus respectivos valores de desvio padrão, o erro proporcional de distância entre centros e o tempo médio da abordagem.

Tabela 19: Resumo dos resultados de desempenho de segmentação

ID	Abordagem	F-score	Desvio Padrão	Erro Distância	Tempo (ms)
16	CrCgCb (Cg)	96,22	1,31	0,35	85,51
14	i1,i2,i3 (i3)	96,03	1,61	0,30	70,52
21	Excess Green em RGB	95,99	1,67	0,32	54,47
11	YCrCb (Cr + Cb)	95,89	2,28	0,44	41,68
9	Luv (v^* - 1,4 u^*)	95,62	4,21	0,75	174,21
17	CrCgCb (Excess Green)	95,59	1,67	0,29	134,00
22	NDI (manual)	95,19	1,61	0,35	98,77
2	HSV (Intervalo)	95,09	1,92	0,51	23,90
6	Lab (b^* - a^*)	94,89	7,46	0,98	60,22
15	I,V1,V2 (V1 - manual)	94,61	1,66	0,36	111,79
8	Luv (v^* - u^*)	93,74	11,26	1,38	118,39
7	Luv (u^* - manual)	93,72	2,36	0,54	85,17
12	l1,l2,l3 (l3)	93,15	7,53	1,37	493,76
5	Lab (a^*)	92,49	10,65	1,67	28,69
26	Invariante a iluminação 2 (F1-F2)	91,46	2,71	0,45	792,77
4	XYZ (Y - X)	91,18	11,92	2,13	50,28
18	Excess Green	90,87	5,74	0,53	207,74
13	l1,l2,l3 (l3 - l2)	90,83	4,72	0,69	543,02
3	HSV (H)	89,14	19,01	2,03	25,83
25	Invariante a iluminação1 (F1-F2)	87,82	7,22	0,84	796,15
23	NDI	87,18	6,79	0,83	102,97
10	YCrCb (Cr)	77,12	23,79	5,20	22,62
20	Excess Green minus Excess Red	74,95	19,22	1,21	214,07
1	OTSU	34,36	18,21	8,49	10,67
24	NDI Modificado	27,98	24,04	5,46	103,87
19	Excess Red	15,68	5,25	6,26	213,43

Nota-se nesta relação que algumas abordagens apresentaram ótimos resultados de segmentação, sendo que entre as melhores respostas observamos também baixo desvio padrão, evidenciando a robustez do método pela baixa susceptibilidade as condições de iluminação. Entretanto algumas desta abordagens como o Luv(v^* -1,4 u^*) e Lab (b^* - a^*) apesar dos bons resultados mostraram uma variação consideravelmente maior, indicando alguma vulnerabilidade destes métodos a condições específicas da cena.

A abordagem HSV (Intervalo) representa neste experimento a abordagem clássica de segmentação por cor, servindo como base comparativa para os resultados. Sua resposta foi boa e com valores de F-score acima de 95%, entretanto 7 outras abordagens obtiveram resultados médios superiores. Contudo após a análise de variância dos dados pode-se afirmar com significância estatística ($p\text{-valor} < 0,05$) que apenas as quatro primeira abordagens tiveram valor de F-score comprovadamente maiores que a abordagem referência. Vale

destacar que o valor de f-crítico ficou muito próximo para o método CrCgCb (*Excess Green*), atingindo um p-valor de 0,08, e que ao se realizar a mesma análise de variância para a métrica erro da distância, seu p-valor atinge 0,0007, mostrando comprovada superioridade neste método em se obter o centro do objeto de interesse.

Existe uma grande correlação entre o erro de distância de centros e o F-score; nota-se que os maiores valores desta métrica acompanham resultados pequenos de erro. Este resultado é esperado dado que uma segmentação perfeita (f-score=100%) irá consequentemente resultar na coincidência dos centros e ausência de erro. Entretanto esta relação não é direta, observa-se que as menores divergências de centro não seguem exatamente a mesma ordem do desempenho de segmentação, os resultados mais precisos para o rastreamento de objetos estão em sequência associadas as abordagens *Excess Green* em CrCgCb, i3 e *Excess Green* em RGB, e apenas na quarta melhor resposta temos a abordagem proposta Cg, responsável pelo melhor resultado geral de segmentação.

Esta divergência de resultados ocorre, pois a medida do centro é mais impactada pela métrica de classificação de precisão, diferente do F-score, em que as métricas de precisão e sensibilidade tem o mesmo impacto no resultado. Em outras palavras, para um baixo erro de distância, é necessário que os falsos positivos (erro tipo 1) sejam muito baixos, mas não necessariamente o número de verdadeiros positivos devem ser altos, principalmente se as classificações corretas estiverem próximas do centro do objeto. Esta característica da métrica favorece portanto os métodos mais conservadores de classificação, a exemplo pode-se observar as respostas do método tradicional *Excess Green*, que apesar do resultado insatisfatório de segmentação tem um erro baixo de distância de centro, equiparável ao resultado do método referência. Adicionalmente vale destacar que este e os melhores métodos para detecção de centros tem como característica comum o conceito de subtração dos tons verdes pelos vermelhos.

De forma geral, nota-se que os melhores resultados se basearam na conversão e relações entre os canais dos espaços de cor YCrCb, L*u*v* e o próprio RGB. Entre estas alternativas, os tempos de processamento são razoáveis demonstrando grande potencial de aplicação. Em sequência os resultados das abordagens mais promissoras serão discutidos em detalhe provendo informações de suas características.

HSV(Intervalo): Iniciando a análise pelo método referência, este apresenta um bom resultado geral e um dos menores tempo de processamento; entretanto outras abordagens mostraram resultados mais promissores de segmentação. Nesta abordagem algumas condições particulares reduziram a métrica para valores próximos de 90%, em especial a condição com menor índice de iluminação: o fim de tarde, nublado, com sombra para a soja (vide Figura 32). Este fator aliado aos resultados encontrados nos experimentos anteriores (A2) da falha do método em luz amarela, aumentam a suspeita da vulnerabilidade à cromaticidade da fonte luminosa e de situações com baixa luminosidade. Este aspecto foi

observado também na análise de efeitos, em que a interação da cromaticidade da muda e horário do dia, demonstraram serem os responsáveis pelo maior impacto no resultado, apontando novamente a dependência do método a captura do objeto dentro dos valores cromáticos especificados.

Figura 32: Variability chart do F-score(%) para abordagem HSV(Intervalo)

HSV(H): Esta abordagem teve resultados inaceitáveis de segmentação, mas por ser baseado na abordagem clássica e estar presente no experimento anterior (A3), sua análise provê informações da consistência dos experimentos e das correlações entre os ambientes interno e externo. Assim como no experimento 2, o resultado desempenhou bem na luz amarela com incidência direta, mas em luz branca, ou em condições de fim de tarde difuso (em que a luz amarela se aproxima do branco) os resultados ficaram instáveis com grandes falhas de segmentação (vide Figura 33). Assim como método anterior o efeito da planta com o horário foi muito significativo, mas o efeito do horário com a intensidade foi ainda mais forte.

Figura 33: Variability chart do F-score(%) para abordagem HSV(H)

CrCb(Cg): Apesar de não ser a abordagem com o melhor resultado em nenhuma das configurações experimentais, foi a que apresentou o melhor resultado médio, garantindo esta posição pela elevada robustez as condições da cena. Seus piores resultados ocorreram nas cenas de milho na iluminação direta, condição de alta presença de destaques luminosos, entretanto seu pior valor não ficou abaixo dos 93%, sendo que no período da tarde os

resultados ficaram ainda melhores e mais constantes (vide Figura 34). O método se mostra bem promissor pela robustez a iluminação e custo computacional relativamente baixo de 86 ms.

Figura 34: Variability chart do F-score(%) para abordagem CrCgCb(Cg)

i1,i2,i3 (i3) e *Excess Green* em RGB: Estes métodos foram agrupados e serão discutidos juntos pois sua formulação é muito similar o que acarretou em resultados igualmente similares. Como diferença fundamental o canal i3 tem uma divisão adicional pelo valor 4, como ambos são submetidos pela abordagem Otsu de limiarização, os resultados deveriam idealmente ser os mesmos independente da escala dos valores, entretanto os resultados de segmentação para o canal i3 ficaram ligeiramente superiores a da abordagem *Excess Green* em RGB, entretanto sem significância estatística. A diferença pode ser explicada pela conversão do tipo dos dados e arredondamentos necessários para o canal i3. O que acarreta também em um maior custo computacional para esta abordagem, portanto pela proximidade dos resultados e a clara vantagem computacional do *Excess Green* em RGB, este último será considerado nesta e demais análises. Para estes métodos a análise dos efeitos mostrou que a maior influência nos resultados é decorrente do objeto, com as cenas com soja, possuindo os melhores resultados. Contudo, assim como os demais métodos analisados, a influência da interação da cromaticidade da fonte e da incidência foram também significantes (vide Figura 35).

Figura 35: Variability chart do F-score(%) para abordagem *Excess Green* em RGB

YCrCb (Cr+Cb): É método com o menor custo computacional com desempenho de segmentação melhor que o método referencia HSV. Seus resultados foram em geral bons, sendo os valores associados a soja muito próximos dos obtidos com a abordagem Cg. Entretanto mostrou grande influência ao tipo de muda, com alto efeito deste fator, obtendo piores resultados para o milho em todas as condições, em especial ao dia, com sombra, com incidência direta (vide Figura 36).

Figura 36: Variability chart do F-score(%) para abordagem YCrCb(Cr+Cb)

Excess green CrCbCg: Abordagem em destaque por apresentar o menor erro de distância entre centros, sua precisão foi a mais elevada entre os métodos com valor médio de 98,6%, mostrando-se uma abordagem altamente criteriosa e com considerável sensibilidade. Seus resultados foram no geral bons e susceptíveis as mesmas influencias das demais abordagens, sendo a planta e interação horário e incidência os efeitos mais significativos, entretanto seu tempo computacional relativamente alto (134 ms) pode ser um limitador para aplicações mais rigorosas (vide Figura 37).

Figura 37: Variability chart do F-score(%) para abordagem *Excess green* em CrCbCg

$L^*u^*v^*$ (u^*-v^*) e $L^*a^*b^*$ (b^*-a^*): Ambas as abordagens baseadas nos espaços de cor uniformes, mostraram ótimas respostas de classificação, apesar de não apresentarem os melhores resultados gerais. Ambas tiveram falhas críticas, com elevada presença de falsos positivos, na condição de maior destaque luminoso, com a incidência direta da luz

branca, no milho com sombra, atingindo valores inferiores a 66% de F-score. A abordagem baseada no $L^*u^*v^*$ se mostrou ainda mais instável sob nesta condição, gerando também segmentação inconsistente para a muda de soja. Entretanto ao desconsiderar esta condição de sombra parcial na luz direta do dia, ambas as abordagens desempenharam muito bem, com os melhores resultados de segmentação, inclusive superiores aos obtidos na abordagem Cg (vide gráfico comparativo da Figura 38). Apesar da pequena diferença o método u^*-v^* desempenhou melhor que o b^*-a^* , com os melhores resultados de F-score em 11 das 16 condições experimentais testadas, a grande vantagem do último reside no tempo de processamento significativamente menor de 61ms, frente a 119ms.

Figura 38: Comparativo do F-score(%) entre a abordagem Cg em verde e a u^*-v^* em azul.

Apesar da grande diferença dos resultados entre as abordagens, nota-se algumas tendências e similaridades, demonstrando um certo padrão de resposta às condições climáticas. Para a constatação destas características, uma análise das configurações experimentais é realizada através da média em cada condição para todas as abordagens, desta forma, pode-se observar quais situações apresentaram maior ou menor desafio de segmentação independente da abordagem (vide gráfico da Figura 39).

Figura 39: Resultado do F-score(%) com a média das abordagens.

Analisando o gráfico tem-se inicialmente que a planta tem grande influência na resposta, a soja teve melhores resultados de desempenho em quase todas as situações, sendo que o efeito diminui no fim da tarde, possivelmente pela influência da cromaticidade

da fonte luminosa no objeto. Acredita-se que estes resultados são justificados pela diferença de textura dos objetos, a muda de milho possui além de um tom levemente mais claro de verde, uma estrutura mais lisa, o que favorece a reflexão da iluminação, transmitindo melhor os tons da fonte luminosa assim como intensificando a presença de destaques luminosos, em contrapartida a estrutura rugosa da soja preserva melhor a cromaticidade original do objeto sob iluminação.

Em geral a condição mais crítica para a segmentação foi a de incidência luminosa direta ao longo do dia, em especial em condições de sombra parcial. Esta condição favorece a ocorrência de destaques luminosos, gerando valores muito próximos ou superiores ao da saturação superior (branco), dificultando a percepção dos tons esverdeados levando consequentemente a falhas de detecção, além disto a sombra parcial facilita a formação de distribuições bimodais de cores o que pode confundir a limiarização por Otsu, utilizada em muitas das abordagens, levando a pontos de corte inapropriados. É importante destacar que em aplicações reais, esta condição crítica tem alta probabilidade de ocorrência, sendo um dos cenários típicos do ambiente externo agrícola, constituindo um grande ponto de atenção e oportunidade.

O contrário se prova também verdadeiro com a observação dos melhores resultados sob luz difusa e luz branca; o tempo nublado, reduz a ocorrência dos destaques e gera uma iluminação mais uniforme e menos intensa sob o objeto e detritos, nestas condições as abordagens se mostram mais estáveis e seus resultados mais similares, apresentando os menores desvios entre todas as configurações. Já no fim do dia nota-se que os efeitos dos demais fatores é diminuído, como objeto, sombra e incidência. Entretanto os desvios e divergências entre as abordagens são intensificados, o que evidencia as diferenças de sensibilidade dos métodos à cromaticidade amarelada da fonte. Sumarizando esta discussão dos resultados a Tabela 20 consolida as observações da análise prática.

Tabela 20: Resultado médio das abordagens por condição experimental,

Fatores Experimentais			F-score (%)	
Cromaticidade da Fonte	Incidência Luminosa	Sombra	Média	Desvio padrão
Dia	Direta	Presença	85,10	16,41
Dia	Direta	Ausência	91,47	8,31
Dia	Difusa	Presença	94,79	3,91
Dia	Difusa	Ausência	94,45	3,06
Tarde	Direta	Presença	93,00	8,55
Tarde	Direta	Ausência	91,16	12,18
Tarde	Difusa	Presença	90,33	12,69
Tarde	Difusa	Ausência	93,19	10,98

A análise de efeitos, também confirmou algumas das observações feitas, mas nenhum fator teve grande destaque nos resultados, mostrando a relevância dos fatores elencados

para o experimento. Os fatores mais críticos foram a planta, a incidência luminosa e a interação do horário com estes dois fatores. Como esperado os aspectos cromáticos da cena tem maior influência, sendo estes provenientes da interação da planta com a iluminação e a quantidade de pontos de alta reflexão (vide Figura 40).

Figura 40: Gráfico de Pareto dos efeitos pela média das abordagens.

Como já discutido, para o experimento 4, as abordagens mais promissoras desta avaliação foram selecionadas constituindo as estratégias com maior potencial de segmentação, estas serão combinadas com abordagens de constância de cor para verificar se resultados ainda melhores podem ser obtidos. Ao fim foram selecionadas as seguintes 10 abordagens e suas características e justificativas seguem em sequência:

- HSV(Intervalo) - Método clássico de segmentação por cor, além de bons resultados segue como referência para o comparativo
- HSV(H) - Abordagem clássica com limiarização por Otsu ao invés da manual, serve como comparativo entre abordagens e experimentos
- CrCgCb(Cg) - Melhor resultado médio de desempenho de segmentação e melhor consistência; com baixa variação entre as condições experimentais
- CrCgCb(*Excess Green*) - Melhor resultado de rastreamento, além de bons resultados de segmentação

- *Excess Green* em RGB - Apresenta ótimos resultados com relativo baixo custo computacional
- YCrCb (Cr+Cb)- Abordagem mais bem sucedida com baixo custo computacional, mas apresenta falhas consideráveis de consistência em condições críticas de iluminação, sendo recomendada em casos críticos de processamento.
- $L^*u^*v^*(u^*-v^*)$ - Demonstrou as melhores respostas quando fora da condição crítica de luz branca, com incidência direta com sombra; mostrando sinais de vulnerabilidade, mas também de potencial. Podendo ser utilizada apenas nas condições favoráveis ou com métodos que suprimam os efeitos indesejados da iluminação.
- $L^*a^*b^*(b^*-a^*)$ - Resultados promissores como o $L^*u^*v^*$ compartilhando de suas características e apesar de resultados inferiores possui menor custo computacional.
- NDI (manual) - Bom desempenho geral de segmentação, com alto valor de F-score, baixo erro de distância e considerável consistência. Além disto foi o método com melhor resposta na configuração crítica do milho com sombra parcial sob incidência direta de luz branca.
- 11,12,13 (13) - Apesar dos valores insatisfatórios neste experimento, este método mostrou bons resultados em condições críticas de iluminação nas análises preliminares, estima-se que os métodos de constância de cor, possam aprimorar o potencial deste método.

De forma a proporcionar um melhor comparativo e visualização das abordagens selecionadas, o gráfico de bolha da Figura 41, combina a informação do custo computacional (tempo normalizado por Otsu) no eixo logarítmico x , os resultados de F-score no eixo y , e a robustez do método as condições de iluminação, com o desvio padrão do F-score como parâmetro para o diâmetro das bolhas.

Finaliza-se assim a análise do primeiro comparativo, avaliando 26 diferentes abordagens de segmentação sob diversas condições de iluminação, pode-se destacar as seguintes conclusões:

- Uma boa estimativa dos tempos de processamento das abordagens foi realizado, apesar das variações presentes em alguns métodos. A conversão de dados, quantidade e natureza das operações matemáticas foram os aspectos determinantes para o custo computacional das abordagens.
- Uma grande variedade de resultados de segmentação foram obtidos, mas em geral os resultados foram bons, mostrando eficiência na etapa de pré-seleção.

Figura 41: Gráfico de bolha das abordagens selecionadas para os próximos experimentos, destaque em azul para o método referência HSV(intervalo).

- Várias abordagens apresentaram resultados superiores ao método de segmentação referência HSV, com destaque as abordagens propostas baseadas no espaço CrCgCb e no conceito do *Excess Green*.
- Abordagens mais conservadoras mostraram melhores resultados para o rastreo do objeto, em especial as abordagens baseadas na subtração dos tons verdes pelos vermelhos.
- Dez abordagens promissoras foram identificadas e selecionadas para avaliações aprofundadas nos demais experimentos, suas escolhas baseiam-se nos resultados obtidos neste experimento assim como o potencial resultado quando em combinação com métodos de constância de cor.
- Em relação aos fatores, as características do objeto se mostram extremamente relevantes, a cromaticidade da planta e principalmente sua textura, interagem com as condições do ambiente e impactam significativamente os resultados das abordagens. A cromaticidade da fonte tem grande influência nos resultados, especialmente na estabilidade dos métodos, com maior a divergência entre abordagens sob iluminação amarela. Já a incidência difusa, decorrente de dias nublados, se mostra como a condição mais favorável para a segmentação, enquanto a luz direta e existência de sombras alteram mais a cromaticidade do objeto de interesse e ruídos na cena, intensificando a ocorrência de destaques luminosos, dificultando a identificação correta da muda.

4.4 Resultados do experimento 4

O segundo experimento comparativo combina as 10 abordagens mais promissoras de segmentação com as 12 tratativas de constância de cor mais a ausência de tratativa, totalizando 130 diferentes estratégias. A análise de tempo para este experimento ficou limitada as abordagens de constância de cor, que por sua vez foram implementadas e calculadas no software Wolfram Mathematica, devido sua facilidade e velocidade de desenvolvimento. Para cada investida de invariância houve a observação de 80 instâncias que compuseram a Tabela 21 com os tempos médios dispostos em ordem crescentes assim como a estimativa de tempo no módulo embarcado, através do fator de escala de 3,61 obtido no experimento 1 para a resolução de 640x320.

Tabela 21: Tabela de tempo de processamento (ms) para abordagens de constância de cor

ID	Método	Tempo WM	Tempo estimado para Rpi
0	Sem invariância	0,00	0,00
1	Referencia média	52,20	188,43
2	Referencia máxima	52,69	190,21
5	<i>Scale By Max</i>	57,99	209,35
3	<i>GrayWorld</i>	59,77	215,76
4	<i>GrayWorld</i> para Média	65,91	237,95
6	<i>Scale By Max</i> com percentil 99,9%	117,71	424,92
7	<i>Scale By Max</i> com percentil 97%	118,10	426,35
10	MSRCR (<i>Exponential</i>)	1249,86	4511,99
12	MSR (<i>Chromaticity preservation 2</i>)	1321,93	4772,18
11	MSR (<i>Chromaticity preservation 1</i>)	1425,26	5145,19
9	MSRCR (<i>Simplest Color Balance</i>)	1462,38	5279,21
8	MSRCR (<i>Gain/Offset</i>)	1553,23	5607,17

Observa-se neste conjunto de dados a existência de três patamares distintos de tempos de processamento, os métodos baseados em ajustes escalares por os canais (1 à 5) possuem tempos similares, com valores próximos a 60 ms. Já para os métodos que incluem também o cálculo do percentil (6 e 7), seu tempo é praticamente dobrado com valores aproximados em 120 ms. Por fim, como antecipado, as abordagens Retinex se mostraram muito exigentes computacionalmente com valores acima de 1s de processamento, constituindo estratégias proibitivas para módulos embarcados em aplicações de tempo real.

Através das previsões de tempo para o módulo embarcado constata-se que as operações de constância de cor são relativamente custosas e as relações entre processamento e desempenho de segmentação deve ser devidamente ponderadas. É possível que existam oportunidades de melhorias nos algoritmos e estratégias de processamentos para reduzir o tempo estimado com a implementação em baixo nível (Python e OpenCV), mas a reprodutibilidade obtida nos experimentos anteriores não dá margem a estimativas muito

mais optimistas. Como alternativas para viabilizar algumas das estratégias, tem-se como opção reduzir a resolução das imagens, gerando reduções de tempo proporcionais a redução do número de píxeis, ou simplesmente utilizar hardwares mais novos ou potentes que os analisados no estudo.

Novamente pelo número excessivo de dados, algumas considerações e organizações nos resultados foram realizadas para observação dos impactos das investidas de invariância. Para tanto cada método foi representado pela média de seus 80 dados, oriundo dos fatores experimentais e 5 repetições, estes resultados foram então agrupados pelas abordagens de pré-processamento utilizadas formando o gráfico da Figura 42.

Figura 42: Resultado de F-score(%) da média das abordagens agrupados por método de constância de cor.

Nota-se inicialmente que as respostas de desempenho foram muito variadas, mas em geral as abordagens de constância de cor não geraram melhora nos resultados, pelo contrário reduziram o desempenho médio e aumentaram a diferença entre as abordagens. Existem, contudo, métodos de invariância luminosa que mantiveram o nível de resposta no mesmo patamar que a condição sem a aplicação do pré-processamento; estes resultados são muito promissores, pois asseguram o alto nível de detecção obtido nas abordagens de segmentação mas também promovem uma robustez adicional por trazerem potencial de correções da iluminação em condições mais críticas e intensas que as testadas, expandindo assim a aplicabilidade das soluções.

Pode-se destacar que para todos os métodos de constância de cor a segunda abordagem de segmentação, correspondendo a HSV(H), teve o pior desempenho entre seus pares, como já havia sido observado no experimento número 3. Para muita das estratégias esta diferença é intensificada, destoando muito dos demais valores, caracterizando a resposta como espúria, influenciando negativamente o resultado médio dos correspondentes métodos de invariância. Pela concepção da segmentação e constância de cor esta piora era esperada, pois o esforço dos métodos em destacar o tom vermelho original do solo aliados a formulação da matiz com ponto zero no vermelho, ocasiona em valores para os píxeis de fundo nos dois extremos do canal, o que dificulta a seleção de um ponto de corte adequado pelo método de Otsu. Portanto para uma melhor correspondência das respostas

dos métodos, os resultados comparativos de constância de cor sumarizados da Tabela 22, não considerou os dados oriundos desta abordagem de segmentação.

Tabela 22: Tabela comparativa dos métodos de constância de cor

ID	Método	F-score	Desvio Padrão	Erro Distância	Tempo (ms)
5	<i>Scale By Max</i>	95,12	4,77	0,63	57,99
0	Sem invariância	95,08	5,41	0,66	0,00
6	<i>Scale By Max</i> com percentil 99,9%	94,73	2,94	0,61	117,71
2	Referencia máxima	93,71	8,48	1,16	52,69
11	MSR (<i>Chromaticity preservation</i> 1)	93,38	10,47	0,70	1462,38
1	Referencia média	89,79	13,42	1,85	52,20
7	<i>Scale By Max</i> com percentil 97%	85,09	12,47	1,52	118,10
12	MSR (<i>Chromaticity preservation</i> 2)	78,03	20,92	2,38	1425,26
4	<i>GrayWorld</i> para Média	68,09	29,64	3,34	65,91
10	MSRCR (<i>Exponential</i>)	64,59	31,03	5,70	1249,86
3	<i>GrayWorld</i>	54,70	28,53	3,58	59,77
8	MSRCR (<i>Gain/Offset</i>)	38,93	27,68	7,51	1321,93
9	MSRCR (<i>Simplest Color Balance</i>)	34,95	23,44	7,27	1553,23

Com a observação dos dados da tabela, reafirma-se que, em geral os métodos de constância de cor, neste contexto, impactaram negativamente nos resultados. Entretanto um dos métodos, o *Scale By Max*, gerou melhoras consistentes nos resultados, aumentando o desempenho de segmentação, reduzindo a variação entre os métodos e o erro de distância entre centros. A diferença não é estatisticamente significativa, mas a melhora consistente nos resultados apresenta um ótimo indicio do potencial do método. Seguindo o mesmo princípio o método *Scale By Max* com percentil 99,9% mostrou também ótimos resultados de segmentação, e diminuiu consideravelmente a diferença entre os métodos, apresentando o menor desvio e o menor erro de centros.

Em sequência tem-se o método de referência pelo máximo, com resultados aceitáveis de segmentação, mas erros consideráveis de centros, com um dos menores acréscimos de custo computacional; seguida pela abordagem *Chromaticity preservation* 1, que apesar do grande custo computacional, mostrou valores razoáveis de segmentação e rastreo, entretanto seu alto desvio denuncia que algumas abordagens de segmentação desempenharam melhores com esta estratégia de constância de cor que outras. A partir desta tratativa os resultados de F-score atingem um patamar inaceitável de desempenho médio, desencorajando a recomendação destas estratégias de maneira geral.

De forma a destacar os potenciais individuais das combinações, os métodos serão avaliados e discutidos isoladamente em sequência, do pior ao melhor resultado, e configurações específicas de abordagens quando pertinentes serão evidenciadas. Recomenda-se para observação das características percorridas a verificação da Figura 21.

MSRCR (*Simplest Color Balance*): Assim como outros métodos, a suposição do

universo cinza falhou com a predominância da cor vermelha na cena, atrapalhando o pré processamento. As imagens geradas ficaram desbotadas, e a restauração de cor com os parâmetros utilizados, não foi suficiente para resgatar as cores do objeto de forma efetiva. A melhor das abordagens de segmentação foi a CrCgCb(Excess Green), mas mesmo assim seu valor médio não superou os 55% de F-score, este péssimo resultado aliado ao grande tempo de processamento caracterizam uma grande falha para esta estratégia como um todo.

MSRCR (*Gain/Offset*): Pelos mesmos motivos do método discutido, mas com menor índice de saturação dos extremos este método também não obteve êxito. Seus resultados individuais foram ainda piores, com a melhor resposta abaixo de 50% de F-score.

GrayWorld: Este método falha em sua suposição inicial, o tom predominantemente vermelho, acarreta em um ajuste da imagem que leva a mesma a ter uma aparência azulada, além disto em condições de destaques luminosos o método muitas vezes satura o objeto dificultando a segmentação. As melhores respostas estão associadas as abordagens provenientes do espaço YCrCb, em especial o CrCgCb (Cg) com 76,4% de acerto, evidenciando a robustez destas abordagens mesmo sob tom incorreto na imagem.

MSRCR (*Exponential*): Apesar de melhorar a visualização e reduzir os efeitos das sombras, o retorno exponencial costuma gerar imagens mais escuras, e por vezes, pela prevalência de certas cromaticidades na imagem gera também tonalidades indesejadas à cena. Estas condições impactaram fortemente o desempenho dos métodos, como destaque a abordagem l1,l2,l3 (l3), teve exito na segmentação de algumas imagens críticas mesmo as mais escuras, atingindo um valor médio de 77,4%.

GrayWorld para Média: Da mesma forma que o outro método *grayworld* os tons da cena foram corrigidos tendendo para o azul, entretanto estes efeitos foram intensificados pelo ajuste imposto pela média, por outro lado a saturação dos destaques luminosos foram reduzidas, levando ao fim a uma melhor desempenho. Novamente mesmo sob tons azulados as abordagens baseadas em YCrCg tiveram maior êxito atingindo valores de F-score próximos a 89%.

MSR (*Chromaticity preservation 2*): Esta abordagem retinex, se diferencia das demais por aplicar a correção na imagem em escala de cinza e preservar a cromaticidade da imagem original, portanto não sofreu dos mesmos efeitos de desbotamento ou criação de tonalidade presente nos seus pares. Sua aplicação acarreta em redução dos efeitos adversos de iluminação, especialmente o efeito da sombra, mas manter a cromaticidade original acarreta por vezes em não compensar o efeito do iluminante na cena. Os parâmetros dos percentis em 2% e 98%, se mostraram muito agressivos, gerando além de saturação superior, uma correção exagerada da cromaticidade, acentuando certos ruídos da cena gerados pela interação com o iluminante, aumentando o número de falsos negativos. A exemplo a Figura 43 demonstra uma grande falha ocorrida na melhor abordagem de

segmentação com este pré-processamento, a YCrCb (Cr+Cb) com F-score médio de 90,5%, comparando com o mesmo método com os parâmetros de percentil em 2% e 99,999%.

Figura 43: Comparação dos resultados de segmentação da abordagem Cr+Cb, para os diferentes parâmetros de percentil do método MSRCR (*Chromaticity preservation*).

Scale By Max com percentil 97%: Diferente dos métodos já discutidos, os próximos não sofrem pela predominância da cor vermelha da cena, justificando consequentemente seus melhores resultados de segmentação. Esta estratégia mostrou grande melhora, nas cenas com pouca iluminação e iluminante não branco, entretanto o percentil elevado de 3%, fez com que os destaques luminosos ficassem saturados para o branco dificultando a classificação correta nestes pontos, vide caso retratado na Figura 44. Os melhores resultados foram obtidos com a abordagem Cg, com F-score médio de 91,4%. Foi também, um dos métodos que apresentaram valores muito distintos para a segmentação HSV (H) com resultado médio de apenas 2,8%.

Referência média: Em geral o método apresentou bons resultados de constância de cor, realizando o ajuste da iluminação em condições de baixa luminosidade e de iluminante com cromaticidade diferente da branca. Os resultados apesar de satisfatórios ficaram abaixo da situação base sem a aplicação do método. As maiores falhas ocorreram em condições de sombra parcial, onde a referência encontra-se na sombra, mas parte da cena e do objeto estão recebendo luz direta, nestas situações o ajuste dos valores acaba sendo excessivo, gerando pontos de saturação na planta e aproximando ruídos da imagem a cores

Figura 44: Imagem original no fim de tarde. Imagem resultante do Scale By Max com percentil 97%. Saída da segmentação pela abordagem Cg.

do objeto de interesse. Os melhores resultados foram novamente obtidos na abordagem Cr+Cb, com um resultado médio de 94,4%.

MSR (*Chromaticity preservation* 1): Como discutido, a partir deste método de constância de cor, o desempenho de segmentação já atinge um patamar muito bom de resultados mostrando significantes melhorias, mesmo em comparação com o mesmo método sob diferentes parâmetros de cortes (rever Figura 43). Estes parâmetros reduziram a saturação dos destaques luminosos e gerou cores mais próximas às reais, gerando melhorias expressivas de algumas abordagens como $L^*u^*v^*$ e $L^*a^*b^*$, além de assegurar em 7 das 10 abordagens testadas um valor médio de F-score acima de 95%; as respostas são promissoras mas seu elevado custo computacional é um grande impeditivo de sua aplicação.

Referência máxima: O ajuste da imagem a partir da referência em seu valor máximo gerou por muitas vezes imagens mais escuras que as originais, mas reduziu significativamente a ocorrência da saturação superior da imagem assim como atenuou o efeito da falha da referência sob condições de iluminação distintas ao do objeto, o que elevou consideravelmente os resultados do método. Vale destacar, que no experimento a referência não estava presente no exato momento da foto e, portanto, a estimativa da iluminação ocorria nos momentos próximos a captura. Assim resultados mais consistentes podem potencialmente ser obtidos se a avaliação da referência ocorrer em tempo real. As melhores respostas estão associadas as abordagens *Excess Green* em CrCgCb e RGB, com F-score de 95,7% e 95,4% respectivamente.

Scale By Max com percentil 99,9%: Como constatado a redução do intervalo de corte superior, melhorou de forma significativa e consistente os resultados, a ocorrência da saturação caiu consideravelmente, reduzindo as falhas de segmentação, e os ajustes de constância de cor se mostraram eficazes apesar do impacto menos expressivo nas imagens. Destaque as abordagens Cg, (v^*-u^*) e (b^*-a^*) , todas com mais de 95% de F-score.

Sem invariância: Os bons resultados da não aplicação de métodos de constância de cor, permite algumas ressalvas e observações interessantes. Inicialmente este resultado é um

indicativo da robustez inerente das abordagens de segmentação as condições de iluminação, mostrando a eficácia da seleção realizada nas investidas e estudos anteriores. Além disto, o fato de não existir resultados significativamente superiores, evidencia a possibilidade de algumas das condições nas abordagens já terem atingido um limite prático de segmentação, em que os pequenos erros de segmentação existentes, na ordem de apenas 3%, possam ser oriundos do processo imperfeito de criação manual de imagens de referência. Por fim e não menos relevante, esta resposta pode indicar que as condições de teste não foram suficientemente agressivas para que as estratégias de constância de cor se mostrassem mais necessárias.

Scale By Max: Método clássico do *Scale By Max*, gerou os melhores resultados sob estas condições experimentais. Por não se basear na média da cena e sim nos maiores valores da imagem, reduz a ocorrência da saturação e não é influenciado por uma cor predominante a cena; mas assegura as correções de cromaticidade esperadas para a iluminação. Sua melhora foi consistente e observada em 7 das 10 abordagens de segmentação, com perdas pouco significativas nas outras 3, evidenciando o potencial de melhora e principalmente de aumento da robustez a condições desconhecidas e extremas de iluminação. Sua simplicidade de aplicação e custo computacional relativamente baixo sem a necessidade de referências e hardwares adicionais evidenciam o potencial do método. Os melhores resultados foram obtidos com a abordagem de segmentação Cg; o pré-processamento manteve os bons resultados originais, mas também auxiliou em algumas condições específicas, aprimorando a segmentação e mantendo os resultados mais estáveis entre fotos e condições (Vide gráfico da Figura 45). Com destaque as melhoras estatisticamente significantes que o método gerou aos resultados na condição crítica de iluminação apontadas no experimento número 3, início da tarde(luz branca) com incidência direta.

Figura 45: Comparativo do F-score(%) entre a abordagem Cg sem pré-processamento em verde e Cg após *Scale By Max* em azul

Comparando individualmente as diferentes estratégias de segmentação, observa-se uma predominância dos métodos de invariância e das abordagens de segmentação para os melhores resultados. Ao todo 22 estratégias desempenharam em média melhor que a

abordagem referência HSV, e seus resultados estão retratados na Tabela 23. Os resultados das melhores estratégias também podem ser contemplados no gráfico de bolha da Figura 46, cujas características são as mesmas do gráfico de bolha do experimento anterior, mas com a adição das cores para representação dos métodos de constância de cor.

Figura 46: Gráfico de bolha dos 10 melhores resultados de F-score, com a adição do baseline, HSV(intervalo) sem invariância.

Os melhores métodos de constância de cor se atêm aos que se mostraram promissores nas discussões anteriores, enquanto para as abordagens, nota-se que as mais recorrentes são as baseadas no espaço de cor YCrCb, com destaque novamente a abordagem Cg, com ótimas respostas de segmentação, seguida por Cr+Cb com bons resultados mas menos consistente, e novamente com os menores erros de distância entre centros as respostas das abordagens CrCgCb(*Excess Green*).

Contudo o melhor resultado médio foi obtido pela combinação do *Chromaticity preservation* 1 (cortes em 2% e 99,999%) e a abordagem $L^*u^*v^*$ (v^*-u^*), comprovando o potencial observado no experimento anterior e demonstrando que com a devida correção dos efeitos luminosos, reduz-se as vulnerabilidades do referido espaço de cor, aumentando consideravelmente seu poder discriminativo. Nota-se também que com os métodos de invariância outras configurações que fazem uso do $L^*u^*v^*$ e $L^*a^*b^*$ conseguiram desempenho acima da referência, condição que não se mostrava possível sem o pré-processamento. Nesta relação pode-se observar também a combinação da abordagem *Excess Green* em

RGB com inúmeros métodos de constância de cor.

Tabela 23: Comparativo do desempenho médio de segmentação das estratégias por F-score

Método de Invariância	Abordagem de Segmentação	Média	Desvio Padrão	Erro Distância
<i>Chromaticity preservation 1</i>	Luv (v^*-u^*)	96,40	1,65	0,41
<i>Scale By Max</i>	CrCgCb (Cg)	96,31	1,01	0,28
Sem invariância	CrCgCb (Cg)	96,22	1,31	0,35
<i>Scale By Max</i> (99,9%)	CrCgCb (Cg)	96,00	0,89	0,30
Sem invariância	Excess Green em RGB	95,99	1,67	0,32
<i>Chromaticity preservation 1</i>	Lab (b^*-a^*)	95,91	2,14	0,50
Sem invariância	YCrCb (Cr + Cb)	95,89	2,28	0,44
<i>Chromaticity preservation 1</i>	Excess Green em RGB	95,86	2,12	0,28
<i>Scale By Max</i>	Excess Green em RGB	95,83	1,60	0,31
<i>Chromaticity preservation 1</i>	YCrCb (Cr + Cb)	95,82	2,37	0,34
Referência máxima	CrCgCb (Excess Green)	95,79	1,80	0,42
<i>Scale By Max</i>	YCrCb (Cr + Cb)	95,74	1,92	0,37
Sem invariância	CrCgCb (Excess Green)	95,59	1,67	0,29
Referência máxima	Excess Green em RGB	95,44	5,12	0,80
<i>Chromaticity preservation 1</i>	CrCgCb (Excess Green)	95,36	2,32	0,27
<i>Scale By Max</i>	CrCgCb (Excess Green)	95,33	1,73	0,32
<i>Chromaticity preservation 1</i>	NDI (manual)	95,29	1,54	0,34
<i>Scale By Max</i> (99,9%)	Luv (v^*-u^*)	95,28	4,92	0,92
<i>Scale By Max</i> (99,9%)	Lab (b^*-a^*)	95,22	2,30	0,42
Referência máxima	YCrCb (Cr + Cb)	95,21	5,95	0,89
Sem invariância	NDI (manual)	95,19	1,61	0,35
<i>Chromaticity preservation 1</i>	HSV (Intervalo)	95,14	1,83	0,52
Sem invariância	HSV (Intervalo)	95,09	1,92	0,51

Através deste comparativo estendido, 130 estratégias foram avaliadas, conclusões sobre as abordagens de segmentação puderam ser reforçadas e novas análises referentes ao impacto de métodos de constância de cor foram observadas. Suas conclusões podem ser sumarizadas nos seguintes pontos:

- O tempo de processamento das abordagens é consideravelmente alto, estima-se que para o módulo embarcado os tempos adicionais das operações estejam acima de 180 ms, o que pode ser proibitivo para operações mais críticas. As abordagens baseadas em Retinex exigiram um nível de processamento ainda mais elevado sendo recomendado apenas em aplicações com baixa dependência do tempo.
- Para redução dos tempos de processamento melhoras nos algoritmos ainda podem ser exploradas, como realizar conversões alternativas, *look-up tables* e *multithreading*. Mas ganhos diretos podem ser obtidos com redução da resolução das imagens, assim como o uso de unidades mais poderosas de processamento.

- Sob esta condição experimental a utilização dos métodos de constância de cor acarretam em perda de desempenho de segmentação na maior parte das configurações. Contudo alguns métodos se mostraram promissores, gerando consistência nas respostas e eventualmente melhorias de segmentação. Entre eles pode-se destacar o *Scale By Max* e sua aplicação alternativa com percentil em 99,9% e a utilização da referência com ponto máximo.
- Para a maior parte dos métodos as abordagens baseadas no espaço de cor YCrCb apresentaram os melhores resultados, evidenciando a robustez e eficiência destes métodos na aplicação, mesmo sob as variações da cena impostas pelos pré-processamentos. Outra abordagem de destaque é o *Excess Green* em RGB, com bons resultados gerais em diversas configurações apesar de sua simplicidade.
- Caso o tempo não seja uma restrição o método *Chromaticity preservation 1*, com percentis ajustados em 2% e 99,999%, também geraram resultados promissores, especialmente em combinação com a abordagem $L^*u^*v^*(v^*-u^*)$ consistindo na estratégia com os maiores valores de F-score, com valor médio de 96,40%.
- Apesar da pioria geral nos resultados com a utilização dos métodos de constância de cor, pode-se observar um grande potencial em sua aplicação, com estratégias específicas gerando melhora significativa nos resultados, além de garantir uma robustez adicional ao processo para condições imprevistas de iluminação. Entretanto em diversos métodos as características particulares da cena acarretaram em falhas em suas suposições básicas gerando problemas na correção da iluminação e por conseguinte na segmentação por cor. Outras abordagens se mostraram promissoras, mas cuidados extras devem ser dado ao seus parâmetros livres, especialmente para evitar ajustes excessivos que levem a descaracterização de píxeis, como a saturação de valores ou confusão de ruídos da cena como legítimos.

4.5 Resultados do experimento 5

A ultima investida experimental realizou um comparativo similar ao realizado no experimento anterior mas sob circunstâncias de iluminação mais severas provenientes da luz ao anoitecer, esta situação é caracterizadas pela baixa iluminação e forte cromaticidade do iluminante com tons alaranjados aproximando as cores do objeto de interesse com o fundo; esta condição é mais descaracterizada e apresenta um maior potencial para os métodos de constância de cor.

Assumindo novamente que aspetos da cena não influenciam nos tempos de processamento e que experimentos anteriores já forneceram estimativas válidas para os mesmos, este experimento se limitou a avaliar apenas o desempenho de segmentação das soluções

propostas. De forma análoga, os dados foram organizados pela média das abordagens e divididos pelos métodos de invariância, constituindo o gráfico da Figura 47.

Figura 47: Resultado de F-score(%) da média das abordagens agrupados por método de constância de cor sob condição crítica de iluminação.

Nota-se no gráfico que todas as respostas tiveram grandes perdas de desempenho; a cena como pretendida dificultou muito o processo de segmentação, a saturação inferior se apresenta como um grande problema e os tons verdes da planta ficaram menos perceptivos. Uma captura de cada configuração experimental é ilustrada na Figura 48.

Figura 48: Cenas obtidas para a condição crítica de iluminação.

Observa-se que para a condição sem pré-processamento o resultado médio das 10 abordagens selecionadas, foi de 94,48% para 45,67%, com algumas abordagens apresentando falhas totais de segmentação, com atenção especial a abordagem referência HSV(Intervalo) com resultado médio de apenas 0,13%, indicando a influência do iluminante na descaracterização dos pixels associados a planta para fora do intervalo de corte do canal da matiz relacionado a cor verde. Em contrapartida este comportamento coincidentemente beneficiou o método HSV(H), que sobre esta cena específica apresentou o melhor resultado de segmentação entre todas as configurações, com F-score médio de 92%. Vale ,contudo, a ressalva que seu resultado para as condições do dia não foram satisfatórias, e seu comportamento se mostrou instável em outros experimentos, dependendo fortemente das condições da cena, uma vez que a cromaticidade do solo é tipicamente próxima a ambos os extremos do canal matiz(*Hue*).

Pode se observar que apesar da grande variação de respostas obtidas, a aplicação dos métodos de constância de cor acarreta em melhorias substanciais das respostas,

elevando seus desempenhos e reduzindo as diferenças entre as abordagens de segmentação. Para facilitar esta visualização a Tabela 24, sumariza e organiza em ordem crescente os resultados dos métodos de constância de cor considerando o valor médio de todas as suas abordagens, adicionando os valores de tempos obtidos no experimento anterior associados ao pré-processamento.

Tabela 24: Tabela comparativa dos métodos de constância de cor sob condição crítica de iluminação

ID	Método	F-score	Desvio Padrão	Erro Distância	Tempo (ms)
4	<i>GrayWorld</i> para Média	68,18	16,97	2,98	59,77
2	Referência máxima	67,43	23,57	2,96	52,69
12	MSR (<i>Chromaticity preservation</i> 2)	65,05	31,42	3,46	1553,23
5	<i>Scale By Max</i>	63,72	25,84	3,23	65,91
1	Referência média	62,57	25,92	2,47	52,20
7	<i>Scale By Max</i> com percentil 97%	62,08	26,31	2,40	118,10
6	<i>Scale By Max</i> com percentil 99,9%	57,45	30,12	3,91	117,71
3	<i>GrayWorld</i>	56,31	27,98	4,58	57,99
11	MSR (<i>Chromaticity preservation</i> 1)	51,20	36,38	4,53	1462,38
0	Sem invariância	45,67	34,16	4,58	0,00
8	MSRCR (<i>Gain/Offset</i>)	32,61	31,07	8,73	1249,86
10	MSRCR (<i>Exponential</i>)	29,28	29,18	7,62	1425,26
9	MSRCR (<i>Simplest Color Balance</i>)	21,76	16,36	8,80	1321,93

Observa-se que sob esta iluminação crítica a influência da constância de cor é muito mais expressiva, apenas 3 dos 12 métodos demonstraram resultados piores que a condição sem pré-processamento, as demais geraram grandes ganhos de desempenho de segmentação, com redução do erro entre centros e de variação entre abordagens de segmentação. Além do impacto dos métodos, observa-se a importância da parametrização, com abordagens de mesma natureza com níveis completamente distintos de resultados. Algumas diferenças significativas em relação a condição de teste anterior são observadas; com inversões de destaques entre as tratativas. Como a exemplo, tem-se os altos valores de *GrayWorld* para Média, a inversão de posição dos métodos de *Chromaticity preservation* e *Scale By Max* aparecendo apenas na quarta posição desta ordenação. Em sequência os métodos similares serão avaliados e discutidos, e resultados pertinentes serão evidenciados.

Métodos baseados em Retinex: Iniciando pelos piores resultados temos as abordagens baseadas em Retinex; com a exceção da *Chromaticity preservation*, todas as demais sofreram com a predominância da cor gerada pelo iluminante e o solo, que aliados a existência de grandes regiões de baixa luminosidade, acarretaram em imagens desbotadas que compensaram a iluminação avermelhada para os tons incorretos, sensibilizando os ruídos, objetos de fundo e por vezes até do solo. Estas condições aliadas a limiarização por Otsu, geraram segmentações muito inconstantes e incorretas, que em conjunto com

os resultados observados para o dia reforçam a incapacidade do método de gerar real constância de cor na cena proposta, a exemplo ver Figura 49.

Figura 49: Exemplo do resultado em iluminação crítica da Soja com sombra a partir do Retinex MSRCR (*Gain/Offset*).

Resultados sem constância de cor: Apesar das abordagens testadas serem as mais promissoras, seus resultados sem as tratativas de pré-processamento foram nesta condição crítica em geral insatisfatórias. Entretanto, apesar de não garantir altos valores de F-score algumas abordagens demonstraram algum grau de detecção, capturando e classificando corretamente os pixels menos descaracterizados da cena, configurando uma possibilidade de uso, mesmo que sob desempenho reduzido para determinadas aplicações. A Tabela 25 expõe o resultado médio das 10 abordagens nestas cenas, ordenados em ordem decrescente de F-score, assim como seus resultados obtidos no experimento 3, denominado na tabela como condição normal de aplicação. Como discutido, observa-se que a abordagem HSV(H) apresentou um ótimo resultado de segmentação frente as circunstâncias impostas, e apesar das suspeitas que o bom resultado se dá por uma conjunção particular das condições da cena, o resultado serve como indicativo do potencial de segmentação que pode ser obtido. Em sequência tem-se o método l3, que havia se mostrado promissor na pré-seleção, e se provou um dos mais capazes de identificar a planta sob baixa iluminação e luminosidade alaranjada, mantendo o erro de distância em um valor razoável. Além disto com menor sensibilidade, mas assegurando precisão na classificação, os métodos b^*-a^* e Excess Green em CrCgCb e RGB representam resultados promissores.

Métodos baseados em *Chromaticity preservation*: Para as estratégias associadas ao retinex com *Chromaticity preservation* seus resultados se mostraram altamente dependente dos parâmetros e da intensidade da correção imposta. Em ambos os casos a abordagem garantiu uma melhor visualização da cena, entretanto o ajuste intenso do método e a preservação dos aspectos cromáticos, descaracterizaram a cena. A influência do iluminante e suas interações com as superfícies foi nítida, atribuindo a cor vermelha para o solo e detritos e para a planta uma cor entre o laranja, para a abordagem mais branda com 99,999%, e amarelo, para a investida mais agressiva com corte em 98%. Esta ultima, apesar

Tabela 25: Resultados sem invariância das abordagens de segmentação sob condição crítica de iluminação

Abordagem	F-score condição crítica	F-score condição normal	Desvio Padrão	Erro Distância
HSV (H)	92,40	89,14	5,65	0,66
l1,l2,l3 (l3)	79,78	93,15	12,07	1,69
Lab (b*-a*)	65,25	94,89	17,82	3,21
CrCgCb (<i>Excess Green</i>)	60,12	95,59	15,18	3,42
YCrCb (Cr + Cb)	59,57	95,89	16,73	3,74
<i>Excess Green</i> em RGB	59,46	95,99	15,85	3,60
Luv (v*-u*)	27,97	93,74	22,52	4,77
CrCgCb (Cg)	11,99	96,22	2,41	5,90
HSV (Intervalo)	0,13	95,09	0,22	9,13
NDI (manual)	0,01	95,19	0,02	9,65

de sensibilizar alguns detritos da imagem, corrigiu um pouco mais as tonalidades da planta acarretando em um dos melhores resultados médios. A combinação de ambos os métodos com as abordagens l3 e b*-a* mostraram bons resultados de F-score médio, com valores acima de 84%, vide exemplo de resultado na Figura 50.

Figura 50: Exemplo do resultado em iluminação crítica da Soja com sombra a partir do Retinex MSR (*Chromaticity preservation 2*).

Métodos baseados em *Scale By Max*: Este métodos haviam se mostrado eficazes para iluminação do dia e apresentaram também um desempenho consistente para a nova condição testada, gerando alguns dos melhores resultados de constância de cor. Em via de regra se observou que quanto maior o corte superior mais agressivo é o ajuste, gerando além de uma maior ocorrência de saturação superior uma correção mais expressiva, que em condições críticas de luminosidade acarretam em maior ajuste e valores mais próximos do original. Métodos mais dependentes da cor original verde, como é o caso do método referência HSV(intervalo), foram mais beneficiados com valores de percentis mais baixos. Os resultados médios apenas não refletiram este comportamento pela influência da abordagem HSV(H) que se mostrou muito instável entre as abordagens, mostrando o quão sensível a abordagem é as condições de corte. Apesar disto todos os métodos baseados em *Scale By*

Max geraram impactos significativos e positivos nos resultados, como exemplo a Figura 51 mostra o resultado da abordagem a^*-b^* , que partiu de um F-score médio de 65,3 % atingindo 80.0% com *Scale By Max* com percentil de 97%.

Figura 51: Exemplo do resultado em iluminação crítica da Soja com sombra a partir do método *Scale By Max* com percentil de 97%

Métodos baseados na referência: A utilização da referência neste experimento se mostrou difícil e pouco prática, posicionar a esfera cinza na sombra para as condições do experimento acarretaram em valores praticamente nulos de intensidade, configurando uma referência incorreta que implicaria em saturação superior de grande parte da imagem pelos ajustes excessivos estipulados. A mesma teve de ser devidamente posicionada na cena de forma a assegurar suficiente incidência luminosa, o que em aplicações reais pode não ser possível. Mesmo sob esta condição, a cromaticidade marcante da fonte luminosa, acarretou na estimativa da referência em valores muito pequenos de azul, que ocasionou grande destaque de eventuais de píxeis azuis no objeto, gerando saturação e perda de informações, vide exemplo em Figura 52. Esta saturação é minimizada com a utilização do ponto máximo para estimativa da referência, mas o ajuste é também menos agressivo beneficiando abordagens diferentes de segmentação. Para referência média a resposta da melhor abordagem foi obtida com NDI(manual) com F-score de 83,2%, já para referência máxima tem-se o l3 com 84,5%. Apesar da dificuldade, os métodos baseados na referência se mostraram como uma alternativa válida de constância de cor, restaurando os tons verdes originais da planta.

Métodos baseados em *GrayWolrd*: Apesar dos resultados insatisfatórios nas cenas com iluminação sob condição normal, as abordagens baseadas no método *GrayWolrd* em especial o com ajuste para a média gerou o melhor resultado médio de segmentação para a condição crítica. O tom azulado gerado pela correção do tom predominantemente vermelho, persiste e é ainda mais acentuado nesta condição, mas este ajuste apesar de descaracterizar o fundo, levou o objeto para dentro do intervalo correto e para tons de verdes próximos aos originais. Acredita-se que a condição particular da cena e a pequena presença de píxeis azuis no objeto, contribuem para o resultado. Entretanto esta realidade poderia ser diferente em casos de planta com outra cromaticidade ou sob outras condições de

Figura 52: Exemplo do resultado em iluminação crítica da Soja com sombra a partir do método da Referência

iluminação, como visto nas condições do experimento 4. Em outras palavras, a estratégia é instável e circunstancial e apesar da alta resposta média, não existem grandes destaques individuais, com a exceção do HSV(intervalo) com F-score médio de 82%, vide Figura 53 com resultado exemplo.

Figura 53: Exemplo do resultado em iluminação crítica da Soja com sombra a partir do método *GrayWorld* para média

Ao avaliar o desempenho individual das estratégias nota-se que algumas das melhores respostas foram obtidas com o uso do espaço de cor l1,l2,l3 com limiarização por Otsu no canal l3, sendo superado apenas pelo HSV(H) sob métodos que mantiveram a cromaticidade do iluminante na cena; entretanto sua instabilidade ao longo dos experimentos e sob outras condições de iluminação desencorajam sua utilização. Em contrapartida a abordagem por l3, apesar de não apresentar os resultados mais promissores em condição normal com 93,2% de F-score, já consiste em uma melhoria na segmentação, além de assegurar uma detecção razoável na condição crítica, com valores relativamente altos de F-score sob diversos pré-processamentos. Como destaque tem-se a resposta do método Scale By Max, que gerou uma grande melhora no resultado original de 79,8% para 87,9%, sem perdas nas respostas sob iluminação normal. A Tabela 26 ordenada pelo valor médio de F-score ilustram estes resultados.

Tabela 26: Comparativo das 10 melhores estratégias na condição crítica de iluminação

Invariância	Abordagem	F-score condição crítica	F-score condição normal	Erro Distância
Sem invariância	HSV (H)	92,40	89,14	0,66
Chromaticity preservation 1	HSV (H)	90,91	88,66	1,04
Chromaticity preservation 2	l1,l2,l3 (I3)	88,12	71,08	1,18
Scale By Max	l1,l2,l3 (I3)	87,88	93,68	1,12
Scale By Max (99,9%)	l1,l2,l3 (I3)	87,79	93,21	1,11
Chromaticity preservation 1	l1,l2,l3 (I3)	87,04	93,47	1,05
Chromaticity preservation 2	Lab (b*-a*)	86,85	87,32	1,16
Referência máxima	l1,l2,l3 (I3)	84,48	92,39	1,63
Chromaticity preservation 1	Lab (b*-a*)	83,98	95,91	1,25
Chromaticity preservation 2	YCrCb (Cr+Cb)	83,49	90,55	1,37

Da mesma forma que os experimentos anteriores, para facilitar a visualização dos melhores resultados, um gráfico de bolha combinando as informações mais relevantes, foi desenvolvido e está representado na Figura 54.

Figura 54: Gráfico de bolha dos 10 melhores resultados de F-score em condição de iluminação crítica.

Observa-se nesta relação que os melhores resultados estão baseados nos métodos MSR (Chromaticity preservation), Scale By Max e referência máxima, e para as abordagens,

além dos resultados do HSV(H) e l3 discutidos, bons resultados foram obtidos também com $L^*a^*b^*(b^*-a^*)$ e em YCrCb (Cr+Cb). O experimento se mostrou ao fim capaz de gerar condições mais agressivas de iluminação, implicando em grande queda no desempenho de segmentação e maior oportunidade para avaliar as investidas de constância de cor, entre as conclusões pode-se destacar:

- As condições críticas de iluminação se provaram mais difíceis para a segmentação, com grande queda dos valores médios e falhas totais em diversas abordagens. A descaracterização do objeto foi grande, pela forte influência do iluminante e as grandes áreas de sombra, que geraram saturação inferior e se mostraram extremamente complicadoras para a detecção do objeto, falhando mesmo com as melhores tentativas de pré-processamento da cena.
- Sem a invariância luminosa a abordagem HSV(H) obteve um ótimo resultado considerando as limitações da cena, mas estima-se que seu desempenho é circunstancial e evidências de instabilidade sugerem maiores investigações e cautela em sua utilização, que inicialmente deve ser limitada apenas ao fim de tarde. Outras abordagens de destaque são l3 e b^*-a^* , que mesmo sob má iluminação demonstraram detecção parcial do objeto de interesse. Em contraponto o método referência HSV(intervalo) resultou em falha total, comprovando sua dependência com as características cromáticas do objeto.
- Para os métodos de constância de cor, apesar do grande custo computacional e dependência do iluminante a abordagem MSR(*Chromaticity preservation*) foi a que gerou algumas das combinações mais eficientes entre as abordagens, com l3, b^*-a^* e Cr+Cb apresentando valores acima de 83% de F-Score.
- Os métodos Scale By Max e Referência foram os que geraram melhor constância de cor sob iluminação crítica, tanto visualmente quanto pelos resultados demonstrados com o abordagem referência HSV(intervalo) e outras dependentes da cor verde característica da planta. Para o primeiro método, quanto maior o corte superior e por consequência mais intenso o ajuste, melhor os resultados. Para o segundo diferentes abordagens foram sensibilizadas em cada método de referência, mas a abordagem baseada no máximo além de possuir a maior média representa uma abordagem mais segura por reduzir a ocorrência de saturação nas imagens. Vale a ressalva que devido a baixa iluminação a referência se mostrou pouco prática e vulnerável.
- Algumas configurações se mostraram bem promissoras com resultados aceitáveis dada as limitações da cena. O pré-processamento se mostrou como uma etapa crucial para o desempenho da maior parte das abordagens, restaurando informações necessárias para classificação correta da planta.

- Por fim, foram observadas diferenças consideráveis nas respostas e estratégias recomendadas para esta cena em relação aos resultados obtidos nos experimentos anteriores. Como a condição de baixa iluminação tem menor ocorrência no contexto agrícola, a seleção dos métodos para a operação deve se balizar nos resultados obtidos nas condições ao longo do dia, mas buscar nas respostas do período da noite, robustez para expandir a aplicabilidade do método para condições mais bruscas e menos previsíveis.

4.6 Avaliações Práticas

Combinando as informações adquiridas nos cinco experimentos que compuseram a campanha experimental algumas considerações práticas serão avaliadas nesta seção, buscando adequação das conclusões para as implicações operacionais do ambiente externo agrícola e da natureza particular de diferentes cenários de aplicação; resgatando assim os objetivos do estudo de viabilizar soluções para detecção e segmentação de plantas no contexto agrícola.

Como ressalva é importante reconhecer que os experimentos representam apenas uma pequena fração das condições possíveis das aplicações, especialmente em um cenário tão imprevisível e sem controle como o ambiente agrícola. Contudo os devidos cuidados tomados ao longo da campanha experimental, endossam os resultados dos comparativos, representando tentativas sólidas para obtenção de processos de segmentações consistentes e eficientes, fornecendo assim indícios das estratégias promissoras para o problema de segmentação de plantas. Entre os cuidados comentados pode-se destacar a avaliação sistema de medidas; a criação de uma cena próxima a real; a utilização dos elementos típicos; a captura da cena em ambiente externo; o número de observações e repetições impostas nos experimentos; a estrutura de experimentos planejados com algum dos fatores mais significativos de iluminação e o grande espectro de abordagens testados.

Outra observação relevante reside na constatação da influência do objeto de interesse e fundo nas respostas do desempenho de segmentação, isto é, as características das plantas e solo, como textura, cor e forma interagem de maneiras distintas com as condições de iluminação, gerando consequentemente diferentes respostas para as estratégias de segmentação. Apesar dos indícios observados no primeiro experimento de reprodutibilidade das abordagens entre diferentes mudas, considerou-se para os experimentos comparativos a utilização de mudas mais difundidas e de grande impacto, assim como solo típico da região do estudo. Variações de resultados na aplicação são portanto esperadas de forma que as avaliações e recomendações percorridas em sequência não serão absolutas, mas sim uma exposição das alternativas mais promissoras frente as observações experimentais do estudo.

As avaliações práticas serão contempladas considerando diferentes cenários de apli-

cação, cada qual serão feitas discussões e recomendações das estratégias mais pertinentes. O princípio inicial de separação dos cenários será a disponibilidade computacional, explorando em sequência os períodos do dia e condições de iluminação ao qual serão submetidos. Para suportar estas análises e estabelecer correlação entre os experimentos uma nova métrica para avaliação geral de desempenho foi estipulada com a aplicação de uma média ponderada dos valores obtidos de F-score na condição normal e crítica, baseando-se em uma exposição idealizada de 12 horas de Sol com 2 horas de baixa iluminação e alta cromaticidade, associadas a primeira e ultima hora de incidência de luz solar.

4.6.1 Melhores resultados para aplicações sem restrição de tempo

Para o primeiro cenário considera-se aplicações que não possuem limitação de tempo, desta forma as alternativas computacionalmente exigentes como as baseadas em Retinex são alternativas validas, assim como a utilização de etapas de pós processamento com operações morfológicas. Com a observação da Tabela 23, tem-se que o melhor resultado ao longo do dia foi de 96,4% obtido pelo MSR (*Chromaticity preservation 1*), com cortes em 2% e 99,999%, com a abordagem v^*-u^* , seguido pelos resultados da abordagem proposta Cg, sem invariância e com as abordagens de Scale By Max, vale também o destaque da aplicação direta do Excess Green em RGB.

Para aplicações limitadas as condições de baixa iluminação ou com cenas de alta incidência do tom avermelhado característicos das extremidades do dia, pode-se observar os resultados da Tabela 26. Nesta condição os melhores resultados foram obtidos com Otsu aplicado na Matiz gerando F-score de 92,4% e as combinações de MSR(*Chromaticity preservation 2*) e Scale By Max com a abordagem l1,l2,l3 (l3). Sendo a ultima estratégia, apesar de menos efetiva a mais recomendada pela estabilidade dos resultados.

Por fim para uma segmentação eficiente ao longo de todo espectro de possibilidades, resultados potencialmente muito eficazes podem ser obtidos com a combinação das melhores configurações de cada condição de iluminação, mas isto requer a composição de algoritmos adaptativos e o monitoramento das informações e condições de mudança. Considerando a condição de uma única estratégia para todas as situações, a combinação dos resultados das condições testadas a partir da média ponderada estipulada anteriormente, compõem a Tabela 27. Nesta observa-se que os resultados mais consistentes independente da cena, foram obtidos com a combinação MSR(*Chromaticity preservation 1*) e a abordagem (b^*-a^*), seguido de diversas configurações da abordagem l3, sendo inclusive a única sem invariância a aparecer na relação. Nota-se também que a referida abordagem Retinex assim como a Scale By Max com valores de corte mais brandos foram os métodos mais promissores de constância luminosa.

Tabela 27: Comparativo das 10 melhores estratégias em geral sem restrição de tempo

Constância de cor	Abordagem	F-score condição normal	F-score condição crítica	Média ponderada	Tempo total estimado (ms)
MSRCP 1	Lab (b*-a*)	95,91	83,98	93,92	5205,40
Scale By Max	l1,l2,l3 (l3)	93,68	87,88	92,71	703,11
MSRCP 1	l1,l2,l3 (l3)	93,47	87,04	92,40	5638,95
MSRCP 1	YCrCb(Cr+Cb)	95,82	75,26	92,39	5186,86
Scale By Max (99,9%)	l1,l2,l3 (l3)	93,21	87,79	92,31	918,68
Scale By Max (99,9%)	Lab (b*-a*)	95,22	75,22	91,88	485,14
MSRCP 1	ExG em RGB	95,86	71,51	91,80	5199,66
Scale By Max	Lab (b*-a*)	95,09	74,24	91,61	269,57
Referência máxima	l1,l2,l3 (l3)	92,39	84,48	91,07	683,97
Sem invariância	l1,l2,l3 (l3)	93,15	79,78	90,92	493,76

4.6.2 Melhores resultados para aplicações com restrições moderadas de tempo

Considerando as restrições normalmente impostas em aplicações com captura constante, estabelece-se que abordagens com tempos de processamento acima de 500 milissegundos são inviáveis excluindo automaticamente todas as estratégias com invariância baseadas em Retinex, além de determinadas combinações de métodos de invariância com as abordagens l3, v*-u*, Cg e CrCgCb(*Excess Green*). Tempos acima de 100 milissegundos para condições de rastreamento já geram duras limitações a aplicação, mas o intervalo de resposta foi expandido devido a possibilidade de desenvolvimento de algoritmos mais eficientes, além da possível aplicação das abordagens propostos em hardwares mais poderosos que o módulo Raspberry Pi 3.

Com estas restrições diferentes estratégias se destacam para cada uma das condições de iluminação, gerando as Tabelas 28,29 e 30, geradas pela ordenação dos 10 melhores resultados de F-score em condição normal, crítica e média ponderada respectivamente.

Na primeira relação (Tabela 28) , observa-se os resultados nas condições de iluminação mais comuns em uma aplicação tipicamente agrícola, caracterizando juntamente com a restrição de tempo o cenário de operação mais provável e por consequência o mais alinhado com os objetivos do estudo. Nesta constata-se uma predominância das abordagens baseadas no espaço YCrCb, com as propostas Cg, CrCgCb(*Excess Green*) e Cr+Cb. Entre elas a primeira combinada ao método Scale By Max, promove uma solução muito robusta, mantendo o desempenho de segmentação em altos níveis para as mais diversas condições de iluminação, mesmo com a presença de destaques luminosos e sombras, possuindo além do maior valor de F-score o menor erro de distância entre centros com apenas 0,28%. O *Excess Green* em RGB também se destaca pelos bons resultados de segmentação e baixo erro de distância entre centros, com um dos menores custos computacionais. Nota-se que

Tabela 28: Comparativo das 10 melhores resultados para condições normais de iluminação com restrições moderadas de tempo

Constância de cor	Abordagem	F-score condição normal	F-score condição crítica	Média ponderada	Tempo total estimado (ms)
Scale ByMax	CrCgCb (Cg)	96,31	15,55	82,85	294,86
Sem invariância	CrCgCb (Cg)	96,22	11,99	82,19	85,51
Sem invariância	ExG em RGB	95,99	59,46	89,90	54,47
Sem invariância	YCrCb(Cr+Cb)	95,89	59,57	89,84	41,68
Scale By Max	ExG em RGB	95,83	65,88	90,84	263,82
Referência máxima	CrCgCb (ExG)	95,79	64,07	90,50	324,21
Scale By Max	YCrCb(Cr+Cb)	95,74	66,03	90,79	251,02
Sem invariância	CrCgCb (ExG)	95,59	60,12	89,67	134,00
Referência máxima	ExG em RGB	95,44	66,40	90,60	244,68
Scale By Max	CrCgCb (ExG)	95,33	62,49	89,85	343,34

Tabela 29: Comparativo dos 10 melhores resultados para condições críticas de iluminação com restrições moderadas de tempo

Constância de cor	Abordagem	F-score condição normal	F-score condição crítica	Média ponderada	Tempo total estimado (ms)
Sem invariância	HSV (H)	89,14	92,40	89,68	25,83
Referência média	NDI(manual)	90,70	83,17	89,44	287,20
GrayWorld para Média	HSV(Intervalo)	66,93	82,08	69,46	261,85
Scale By Max (97%)	Lab (b*-a*)	86,03	79,98	85,02	486,57
Sem invariância	l1,l2,l3 (l3)	93,15	79,78	90,92	493,76
Scale By Max (97%)	HSV(Intervalo)	90,21	79,31	88,40	450,25
Referência média	HSV(Intervalo)	87,22	79,18	85,88	212,32
Referência máxima	HSV(Intervalo)	91,97	79,09	89,82	214,11
Scale By Max	HSV (H)	83,37	78,92	82,63	235,17
Referência máxima	NDI(manual)	92,43	77,57	89,96	288,99

entre os melhores resultados muitos não utilizam métodos de invariância sendo o Scale By Max e Referência Máxima as únicas estratégias a aparecer na relação, por gerarem ajustes mais suaves mantendo e melhorando os resultados de segmentação sem custos computacionais excessivos.

Já para a Tabela 29, associado a um cenário bem descaracterizado proveniente da iluminação característica dos primeiros e últimos momentos de luz do dia, tem-se uma grande mudança nas configurações de sucesso. Nenhuma das abordagens baseadas em YCrCb aparece na relação sendo substituídas por tratativas associadas ao HSV, NDI com corte fixo, b*-a* e um único remanescente das abordagens baseadas em l3. Observa-se também que para esta condição os métodos de constância de cor se provam mais necessários

Tabela 30: Comparativo dos 10 melhores resultados gerais com restrições moderadas de tempo

Constância de cor	Abordagem	F-score condição normal	F-score condição crítica	Média ponderada	Tempo total estimado (ms)
Scale By Max (99,9%)	Lab (b*-a*)	95,22	75,22	91,88	485,14
Scale By Max	Lab (b*-a*)	95,09	74,24	91,61	269,57
Sem invariância	l1,l2,l3 (l3)	93,15	79,78	90,92	493,76
Scale By Max	ExG em RGB	95,83	65,88	90,84	263,82
Scale By Max	YCrCb(Cr+Cb)	95,74	66,03	90,79	251,02
Referência máxima	ExG em RGB	95,44	66,40	90,60	244,68
Referência máxima	CrCgCb (ExG)	95,79	64,07	90,50	324,21
Referência máxima	YCrCb(Cr+Cb)	95,21	66,60	90,45	231,89
Scale By Max (99,9%)	HSV(Intervalo)	94,51	68,89	90,24	448,82
Referência máxima	Lab (b*-a*)	93,68	72,90	90,22	250,43

principalmente em configurações cujos ajustes se mostram mais expressivos como referência média e Scale By Max com percentil em 97%. Sendo este último método o responsável pelos melhores resultados percebidos de constância de cor, sendo recomendado juntamente com b*-a* e HSV(Intervalo) como estratégias de segmentação para esta cena crítica. O HSV (H) sem invariância mostrou os melhores resultados de segmentação, com expressiva vantagem das demais estratégias e sua implementação principalmente pela simplicidade e baixo custo computacional são altamente sugeridas, mas cautela é necessária para sua aplicação, dado que o método se mostrou muito susceptível as condições de iluminação. Por fim apesar do bom resultado dos métodos de referência, sua aplicação também requer cuidados, pois sob baixa iluminação o posicionamento da referência se torna crítico, e seus ajustes podem se tornar excessivos caso a referência não tenha exposição suficiente do iluminante.

Na ultima relação (Tabela 30), considera-se uma aplicação que requer o desempenho satisfatório da solução de segmentação ao longo do maior período possível e sob as mais diversas condições de iluminação, este cenário poderia ser útil para operações de rastreamento ou contagem de objetos de interesse, ou demais situações em que o desempenho de segmentação não é o mais crítico e sim a consistência e estabilidade de detecção. Neste observamos novamente a predominância dos métodos de invariância em especial os baseados na referência máxima e Scale By Max com ajustes brandos. Os melhores resultados nestas circunstâncias estão associados a abordagem b*-a* com Scale By Max, o l3 como a única alternativa sem pré-processamento e abordagens baseadas no conceito do *Excess Green*, como a aplicação em RGB e CrCgCb, sendo estas as alternativas com classificação mais conservadora, e portanto com menor taxa de falsos positivos.

4.6.3 Melhores resultados para aplicações com altas restrições de tempo

Neste último cenário as alternativas e recomendações são priorizadas em funções do tempo de processamento, visando aplicações em que existem limitações de processamento, ou que a latência e taxa de aquisição de informações da cena são um aspecto crítico do sistema. Operações de rastreo e identificação de plantas sobre móveis possuem em geral exigências de taxas altas e confiáveis de captura, de forma a não implicar em restrições no movimento e ações do dispositivo. Esta imposição naturalmente favorece a aplicação das abordagens de segmentação sem as etapas de pré-processamento, eliminando o tempo adicional associado aos métodos de constância de cor. A Tabela 31 está ordenada do menor para o maior tempo de processamento mantendo as informações de segmentação.

Tabela 31: Comparativo dos resultados com os 10 menores tempos de processamentos

Constância de cor	Abordagem	F-score condição normal	F-score condição crítica	Média ponderada	Tempo total estimado (ms)
Sem invariância	HSV(Intervalo)	95,09	0,13	79,26	23,90
Sem invariância	HSV (H)	89,14	92,40	89,68	25,83
Sem invariância	YCrCb(Cr+Cb)	95,89	59,57	89,84	41,68
Sem invariância	ExG em RGB	95,99	59,46	89,90	54,47
Sem invariância	Lab (b*-a*)	94,89	65,25	89,95	60,22
Sem invariância	CrCgCb (Cg)	96,22	11,99	82,19	85,51
Sem invariância	NDI(manual)	95,19	0,01	79,32	98,77
Sem invariância	Luv (v*-u*)	93,74	27,97	82,77	118,39
Sem invariância	CrCgCb (ExG)	95,59	60,12	89,67	134,00
Referência média	HSV(Intervalo)	87,22	79,18	85,88	212,32

Com menor custo computacional tem-se as abordagens clássicas de segmentação por cor, baseadas na resposta da matiz do modelo HSV, a utilização do intervalo de corte fixo, apesar de bons resultados na condição normal de iluminação mostra grande dependência da cromaticidade da fonte, e desvios da condição ideal de exposição podem levar a falhas catastróficas do sistema como indicado sob luz no fim da tarde ou sob luz amarela artificial, mostrando a vulnerabilidade da solução. A abordagem com limiarização adaptativa de Otsu, reduz um pouco os efeitos da iluminação, mas compartilha das vulnerabilidades da influência da luz, e em especial apresenta problemas de corte pela concepção do zero de sua escala estar associado ao vermelho, o que ocorre em luz branca representando a cromaticidade mais comum do iluminante na aplicação.

Desta forma a abordagem com menor custo computacional recomendada reside no espaço YCrCb pela simples adição dos canais cromáticos Cr e Cb, a operação é rápida para o sistema e provê ótimos resultados ao longo do dia e detecção razoável em condições críticas. Entretanto na condição de exposição direta com sombra no início da tarde teve eventuais problemas de falsa detecção, com quedas significantes em seu resultado. Com

resultados mais consistentes a melhor relação de segmentação com custo computacional está associada a abordagem Excess Green no próprio RGB, constituindo uma das abordagens mais robustas com também um dos menores erros de distância entre centros de todas as estratégias.

A abordagem baseada no espaço $L^*a^*b^*$ pela subtração dos canais cromáticos b^* e a^* , apresenta uma boa alternativa caso a detecção em condição de iluminação nas extremidades do dia sejam mais importantes, mas falhas ainda maiores que a tratativa $Cr+Cb$ na condição de alta incidência luminosa com sombra foram observadas neste espaço, evidenciando possíveis vulnerabilidades da abordagem aos ruídos da imagem em condição de saturação. A última abordagem de destaque reside da Cg , que apresentou o resultado mais consistente e com maior valor médio de segmentação na condição normal, sendo altamente indicado quando a aplicação se restringe a esta situação e existe disponibilidade de processamento.

Por fim de forma a resumir as avaliações e recomendações fornecidas nesta seção a Tabela 32, contempla os cenários mais prováveis evidenciando para cada um, as melhores combinações entre método de constância de cor e abordagem de segmentação.

Tabela 32: Recomendações de constância de cor e abordagem de segmentação para diferentes condições de aplicação

Aplicação	Constância de cor	Abordagem de segmentação
Dia	Scale by Max e Chromaticity preservation com parâmetros brandos de ajuste	$CrCb$ (Cg)
		Excess Green (RGB)
		$YCrCb$ ($Cr + Cb$)
		$CrCb$ (Excess Green)
Anoitecer	Scale by Max e Chromaticity preservation com parâmetros agressivos de ajuste	HSV (H)
		$l1l2l3$ ($l3$)
		$L^*a^*b^*(b^*-a^*)$
Geral	Scale by Max e Chromaticity preservation com parâmetros brandos de ajuste	$L^*a^*b^*(b^*-a^*)$
		$l1l2l3$ ($l3$)
		Excess Green (RGB)
Alta restrição de tempo	Não utilizar constância de cor	Excess Green (RGB)
		$YCrCb$ ($Cr + Cb$)
		$CrCb$ (Cg)

5 CONSIDERAÇÕES FINAIS

Este capítulo consolida os aprendizados e conclusões obtidos a partir do estudo da literatura e análise dos resultados da campanha experimental, observando suas contribuições sob a ótica dos objetivos propostos. As discussões desta seção estão limitadas as observações gerais e consideradas críticas para o problema de segmentação de mudas de plantas no ambiente agrícola; pormenores dos resultados específicos das estratégias testadas foram tratados com profundidade na seção de resultados e não serão retomados no presente tópico, além disto oportunidades e sugestões de futuros trabalhos serão apresentadas.

5.1 Discussão

Os sistemas de visão já são uma tecnologia presente na agricultura de precisão, e dentre suas diversas aplicações o problema de processamento de imagens para segmentação de plantas consiste em uma etapa inicial e crítica para obtenção de informações valiosas do ambiente, sendo a importância deste processo é equiparável a sua dificuldade de obtenção. As análises conduzidas no estudo demonstraram que o processo de separação e classificação das mudas de plantas são complexos e intimamente dependentes da cena de captura, o que se torna um verdadeiro desafio quando esta é exposta as condições instáveis do ambiente externo sem a utilização de mecanismos de controle da iluminação ou hardwares mais especificados. Estas restrições, incentivadas pela perspectiva da operação e do mercado, visam o baixo custo e acessibilidade da tecnologia, acarretando em limitações de processamento, hardwares, procedimentos operacionais e consequentemente no conjunto de soluções possíveis.

Sob estas de imposições, as análises da literatura sugestionaram os processos de segmentação baseadas por cor como um dos mais efetivos para detecção das plantas; assim dispositivos comuns como câmeras RGB e unidades modulares de processamento, além de software aberto e difundidos foram considerados. Sob esta base, inúmeras estratégias baseadas em segmentação por cor e métodos de constância de cor foram combinadas, comparadas e testadas sob condições diversas e típicas de iluminação. Apesar das dificuldades e de um conjunto de ressalvas os experimentos evidenciaram soluções promissoras com alto potencial de segmentação mesmo sob condições de ruído e descaracterização da cena.

Os experimentos iniciais constataram aspectos importantes das métricas para suportar as demais investidas comparativas. A métrica de tempo de processamento se mostrou precisa e altamente capaz de diferenciar as abordagens, mas o processamento apresentou indícios de instabilidade evidenciando a necessidade de se utilizar mais observações para estimativa dos custos computacionais das abordagens. Constatou-se que os aspectos da cena não influenciaram os tempos de processamento, sejam as condições de iluminação,

os objetos da cena ou a distância do sistema de captura; em contrapartida a resolução influenciou diretamente no processamento, sendo proporcional a quantidade de píxeis. As diferentes unidades de processamentos analisadas mostraram as limitações do hardware modular de baixo custo, mas a reprodutibilidade das respostas observadas tanto em tempo de processamento quanto em desempenho de segmentação permitiu o estabelecimento de fatores de ajuste e encorajaram a utilização de softwares de alto nível para prototipagem e teste de abordagens.

Em relação ao desempenho de segmentação, os primeiros experimentos direcionaram a modificação e melhoria das métricas de classificação, observou-se que o F-score representou uma medida mais precisa e assertiva para a segmentação que o erro total utilizado na primeira investida, sendo utilizada juntamente com a métrica de erro proporcional entre centros para os estudos comparativos. Ambas as métricas se mostraram sensíveis aos métodos e fatores experimentais relevantes, e com o devido aumento do número de repetições experimentais, constituíram variáveis resposta válidas para o sistema de medidas.

Os componentes avaliados nos primeiros testes mostraram que imagens de maior resolução acarretaram em ligeira melhora na segmentação para maior parte das estratégias, mas sua influência não foi preponderante e alta reprodutibilidade entre as respostas foi observada. As diferenças foram atribuídas a perda de precisão na confecção das imagens verdade, cálculos e eventualmente em condições de transição entre objeto e fundo. Os dispositivos de captura apresentaram diferenças significativas de desempenho quanto associadas a abordagens instáveis, onde as desigualdades inerentes da captura se aliavam a baixa separabilidade do método, caso contrário a distinção se tornava pouco perceptível. As operações morfológicas utilizadas como pós-processamento e eliminação de ruídos nas imagens binárias, mostraram melhoras consistentes nos resultados, mas seu aumento de tempo computacional em especial no módulo embarcado não compensaram a pequena melhora gerada, sendo esta operação recomendada apenas em caso de disponibilidade de processamento.

As análises do sistema de medidas evidenciaram também a importante influência da pose nas métricas, sua concepção baseada na proporção das classificações, dificulta um comparativo justo entre cenas com objetos de tamanhos e distâncias distintas, gerando a necessidade de controlar a área de cobertura dos objetos de interesse na cena. Os ruídos gerados pela adição dos detritos na cena foram elementos fundamentais para representatividade dos experimentos e se mostraram como componentes de distinção de resultados em inúmeras abordagens. Por fim a avaliação inicial das métricas demonstrou a grande influência das características da planta, solo e iluminação nos resultados de segmentação; justificando a estrutura de experimento planejada para o comparativo e a utilização alguma das mudas e solos mais difundidos no contexto agrícola nacional, apesar

dos indícios de reprodutibilidade das abordagens entre diferentes plantas.

Os experimentos comparativos proveram informações consistentes dos tempos de processamento e desempenhos de segmentação das abordagens, gerando uma grande variedade de respostas, tanto entre as abordagens quanto para os fatores experimentais. Que comprovaram a influência direta da iluminação e sua interação com a cena nas respostas, evidenciando também que diferentes estratégias respondem de forma distintas a estas condições. Em geral a iluminação direta para o iluminante com cromaticidade branca e sombra parcial representou o cenário mais desafiador para as abordagens, e cenas de dia nublado a condição mais estável e de melhor desempenho. Os grandes problemas de segmentação residiram principalmente na saturação positiva causada por destaques luminosos na planta e detritos, assim como na influência da cromaticidade do iluminante nos elementos da cena, este efeito se acentuou ao anoitecer onde a falta de iluminação também gerou grandes falhas pela saturação negativa da imagem.

Apesar da grande variação nas respostas, algumas abordagens se mostraram promissoras com desempenho elevado em todas as condições impostas, com resultados estatisticamente superiores aos das abordagens clássicas de segmentação por cor. A combinação dos métodos de segmentação promissores com as tratativas de constância de cor para o período do dia não gerou melhora de desempenho significativa, pelo contrário reduziram os resultados em diversas configurações. Contudo algumas estratégias particulares geraram ligeiras melhoras no desempenho que aliadas ao ganho adicional de robustez para condições não previstas de iluminação, representam ótimas soluções para o problema de segmentação. O último experimento confirmou estes ganhos ao simular condições mais críticas de iluminação com o anoitecer, mostrando o potencial dos métodos de invariância luminosa, que elevaram expressivamente os resultados de segmentação.

Os custos computacionais do pré-processamento com algoritmos de constância de cor se mostraram altos, mas seu potencial de ajuste sob condições adversas de iluminação e cena provêm uma comprovada robustez a solução de segmentação sendo recomendados em aplicações com restrições menores de tempo. Caso contrário algumas das abordagens propostas sem as tratativas de constância de cor mostraram elevada consistência e eficiência de resultados quando dentro de certas condições de controle. O estudo ao fim elencou uma série de alternativas promissoras de segmentação, cuja aplicação está orientada quanto a condição de operação do hardware e cena, entretanto até mesmo condições altamente restritivas como sistemas embarcados de baixo custo com demandas de tempo real, possuem alternativas animadoras e viáveis com abordagens de segmentação simples, sem a necessidade de operações de pré ou pós processamento. Estas aplicações carecem ainda de validação e explorações adicionais, mas trabalhos futuros tem a pretensão de contemplar estas análises e consolidar as soluções.

5.2 Propostas para trabalhos futuros

Após a realização do presente estudo algumas oportunidades de exploração foram vislumbradas e podem ser sumarizadas nos seguintes tópicos:

- Comparar o desempenho das abordagens com as respostas de dispositivos de captura infravermelho
- Estudar tratativas alternativas de constância de cor, em especial as baseadas em aprendizagem de máquina, que após o devido treinamento podem gerar resultados rápidos e eficientes de segmentação de plantas;
- Avaliar o custo computacional real dos métodos de constância cor promissores no módulos embarcado, e estudar formas de aprimorar a eficiência dos mesmos;
- Observar os mecanismos e características comuns das estratégias promissoras e desenvolver abordagens mais eficientes e eficazes;
- Propor e avaliar o desempenho de abordagens adaptativas com a composição das melhores estratégias para cada condição de iluminação e cena;
- Replicar o experimento para outras espécies de plantas e diferentes solos, com características distintas das testadas e avaliar a reprodutibilidade e consistência das soluções;
- Expandir a avaliação de desempenho das estratégias promissoras para a aplicação real, aumentando o espectro de cenas e condições de iluminação possíveis;

REFERÊNCIAS

- AGARWAL, V. et al. An Overview of Color Constancy Algorithms. **Journal of Pattern Recognition Research**, v. 1, p. 42–54, 2006.
- AULAKH, A. S.; ARORA, A. A Review on Color Constancy Algorithms. v. 3, n. 4, p. 180–183, 2013.
- BARNARD, K.; CIUREA, F.; FUNT, B. Sensor sharpening for computational color constancy. **JOSA A**, Optical Society of America, v. 18, n. 11, p. 2728–2743, 2001.
- BERNARDI, A. C. d. C. et al. **Agricultura de precisão: resultados de um novo olhar**. [S.l.: s.n.], 2014. 596 p. p. ISBN 9788570353528.
- BIANCO, S.; CUSANO, C.; SCHETTINI, R. Color constancy using cnns. **arXiv preprint arXiv:1504.04548**, 2015.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Agricultura de Precisão. Boletim Técnico. p. 5, 2011. Disponível em: <http://www.agricultura.gov.br/assuntos/insumos-agropecuarios/arquivos-publicacoes-insumos/agric_precisao.pdf>.
- BUENAPOSADA, J. M.; BAUMELA, L. Variations of grey world for face tracking. **Image Processing & Communications**, Citeseer, v. 7, n. 3-4, p. 51–61, 2001.
- CAMARGO, A.; SMITH, J. S. An image-processing based algorithm to automatically identify plant disease visual symptoms. **Biosystems Engineering**, IAgRE, v. 102, n. 1, p. 9–21, 2009. ISSN 15375110. Disponível em: <<http://dx.doi.org/10.1016/j.biosystemseng.2008.09.030>>.
- CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. [S.l.]: Guilford Press, 2011.
- CARDEI, V. C.; FUNT, B.; BARNARD, K. Estimating the scene illumination chromaticity by using a neural network. **JOSA a**, Optical Society of America, v. 19, n. 12, p. 2374–2386, 2002.
- CASADY, W. et al. A trainable algorithm for inspection of soybean seed quality. **Transactions of the ASAE**, American Society of Agricultural and Biological Engineers, v. 35, n. 6, p. 2027–2034, 1992.
- CHAISSATTAPAGON, N. Z. C. Effective criteria for weed identification in wheat fields using machine vision. **Transactions of the ASAE**, American Society of Agricultural and Biological Engineers, v. 38, n. 3, p. 965–974, 1995.
- CHEN, Y. R.; CHAO, K.; KIM, M. S. Machine vision technology for agricultural applications. **Computers and Electronics in Agriculture**, v. 36, n. 2-3, p. 173–191, 2002. ISSN 01681699.
- CIUREA, F.; FUNT, B. A large image database for color constancy research. **Proc. IS&T. SID Eleventh colour Imaging ...**, p. 160–164, 2003.

EBNER, M. A parallel algorithm for color constancy. **Journal of Parallel and Distributed Computing**, v. 64, n. 1, p. 79–88, 2004. ISSN 07437315.

EL-FAKI, M.; ZHANG, N.; PETERSON, D. Weed detection using color machine vision. **Transactions of the ASAE**, American Society of Agricultural and Biological Engineers, v. 43, n. 6, p. 1969, 2000.

FINLAYSON, G. D. Coefficient Color Constancy. n. April, p. 1–191, 1995.

FINLAYSON, G. D.; DREW, M. S.; FUNT, B. V. Spectral sharpening: sensor transformations for improved color constancy. **Journal of the Optical Society of America A**, v. 11, n. 5, p. 1553, 1994. ISSN 1084-7529. Disponível em: <https://www.osapublishing.org/abstract.cfm?URI=josaa-11-5-1553>.

FINLAYSON, G. D.; HORDLEY, S. D. Color constancy at a pixel. **JOSA A**, Optical Society of America, v. 18, n. 2, p. 253–264, 2001.

FORSYTH, D. A Novel Algorithm for Color Constancy. **International Journal of Computer Vision**, v. 5, n. 1, p. 5–36, 1990. ISSN 0920-5691.

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. Disponível em: <http://dx.doi.org/10.1016/j.agwat.2014.08.010>.

GARCÍA-SANTILLÁN, I. D. et al. Automatic detection of curved and straight crop rows from images in maize fields. **Biosystems Engineering**, v. 156, p. 61–79, 2017. ISSN 15375110.

GEVERS, T.; SMEULDERS, A. W. Color-based object recognition. **Pattern Recognition**, v. 32, n. 3, p. 453–464, 1999. ISSN 00313203.

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.

GIJSENIJ, A. et al. Color Constancy by Derivative-based Gamut Mapping. 2008.

GITELSON, A. A. et al. Novel algorithms for remote estimation of vegetation fraction. **Remote sensing of Environment**, Elsevier, v. 80, n. 1, p. 76–87, 2002.

GONZALEZ, R. C.; WOODS, R. E. et al. **Digital image processing**. [S.l.]: Addison-wesley Reading, 1992.

GOWEN, A. et al. Applications of thermal imaging in food quality and safety assessment. **Trends in food science & technology**, Elsevier, v. 21, n. 4, p. 190–200, 2010.

GUERRERO, J. M. et al. Support Vector Machines for crop/weeds identification in maize fields. **Expert Systems with Applications**, Elsevier Ltd, v. 39, n. 12, p. 11149–11155, 2012. ISSN 09574174. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2012.03.040>.

HAMUDA, E.; GLAVIN, M.; JONES, E. A survey of image processing techniques for plant extraction and segmentation in the field. **Computers and Electronics in Agriculture**, Elsevier B.V., v. 125, p. 184–199, 2016. ISSN 01681699. Disponível em: <http://dx.doi.org/10.1016/j.compag.2016.04.024>.

HERNÁNDEZ-HERNÁNDEZ, J. L. et al. Optimal color space selection method for plant/soil segmentation in agriculture. **Computers and Electronics in Agriculture**, v. 122, 2016. ISSN 01681699.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v. 11, n. 3, p. 185 – 200, 1991. ISSN 0167-5877. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167587705800042>.

JEON, H. Y.; TIAN, L. F.; ZHU, H. Robust crop and weed segmentation under uncontrolled outdoor illumination. **Sensors**, v. 11, n. 6, p. 6270–6283, 2011. ISSN 14248220.

JIANG, G.; WANG, Z.; LIU, H. Automatic detection of crop rows based on multi-ROIs. **Expert Systems with Applications**, Elsevier Ltd, v. 42, n. 5, p. 2429–2441, 2015. ISSN 09574174. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2014.10.033>.

JIMENEZ, A.; CERES, R.; PONS, J. A survey of computer vision methods for locating fruit on trees. **Transactions of the ASAE**, American Society of Agricultural and Biological Engineers, v. 43, n. 6, p. 1911, 2000.

JOBSON, D. J.; WOODILL, G. A. **Properties of a center/surround Retinex: Part 2. Surround design**. 1995. 15 p.

KATAOKA, T. et al. Crop growth estimation system using machine vision. **Proceedings 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2003)**, v. 2, n. Aim, p. 1079–1083, 2003.

KOSCHAN, A.; ABIDI, M. DIGITAL COLOR IMAGE Processing. **Image Processing**, p. 375 pages, 2008.

KUMAR, L. et al. Imaging Spectrometry and Vegetation Science. **Imaging Spectrometry. Remote Sensing and Digital Image Processing**, p. 111–155, 2002.

LAM, E. Y. Combining gray world and retinex theory for automatic white balance in digital photography. **Consumer Electronics 2005ISCE 2005 Proceedings of the Ninth International Symposium on**, p. 134–139, 2005. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1502356>.

LAMM, R. D.; SLAUGHTER, D. C.; GILES, D. K. Precision weed control system for cotton. **Transactions of the ASAE**, American Society of Agricultural and Biological Engineers, v. 45, n. 1, p. 231, 2002.

LAND, E. H. Recent advances in retinex theory and some implications for cortical computations: color vision and the natural image. **Proceedings of the National Academy of Sciences**, v. 80, n. 16, p. 5163–5169, 1983. ISSN 0027-8424.

LAND, E. H.; MCCANN, J. J. Lightness and Retinex Theory. **Journal of the Optical Society of America**, v. 61, n. 1, p. 1–11, 1971. ISSN 0030-3941. Disponível em: <http://www.opticsinfobase.org/abstract.cfm?URI=josa-61-1-1>.

LIMARE, N. et al. Simplest color balance. **Monographs of the Society for Research in Child Development**, v. 79, n. 1, p. 125–33, 2014. ISSN 1540-5834.

LIU, T. et al. Automated image-processing for counting seedlings in a wheat field. **Precision Agriculture**, Springer US, v. 17, n. 4, p. 392–406, 2016. ISSN 15731618.

LOU, Z. et al. Color Constancy by Deep Learning. **Proceedings of the British Machine Vision Conference 2015**, p. 76.1–76.12, 2015. Disponível em: <http://www.bmva.org/bmvc/2015/papers/paper076/index.html>.

LUKAC, R.; PLATANIOTIS, K. **Color image processing: methods and applications**. [S.l.: s.n.], 2007. ISBN 9780849397745.

MADDERN, W.; STEWART, A. D.; NEWMAN, P. LAPS-II: 6-DoF day and night visual localisation with prior 3D structure for autonomous road vehicles. **IEEE Intelligent Vehicles Symposium, Proceedings**, p. 330–337, 2014.

MAO, W.; WANG, Y.; WANG, Y. Real-time detection of between-row weeds using machine vision. In: AMERICAN SOCIETY OF AGRICULTURAL AND BIOLOGICAL ENGINEERS. **2003 ASAE Annual Meeting**. [S.l.], 2003. p. 1.

MATSON, P. A. et al. Agricultural Intensification and Ecosystem Properties. **Science**, v. 277, n. October, p. 504–509, 1997. ISSN 00368075. Disponível em: <http://www.sciencemag.org/cgi/doi/10.1126/science.277.5325.504>.

MCCARTHY, C. L.; HANCOCK, N. H.; RAINE, S. R. Applied machine vision of plants: A review with implications for field deployment in automated farming operations. **Intelligent Service Robotics**, v. 3, n. 4, p. 209–217, 2010. ISSN 18612776.

MCMANUS, C. et al. Shady Dealings: Robust, Long-Term Visual Localisation using Illumination Invariance. 2014.

MEYER, G. E. Machine vision identification of plants. **Recent trends for enhancing the diversity and quality of soybean products**, p. 401–420, 2011. Disponível em: <http://cdn.intechweb.org/pdfs/22613.pdf>.

MEYER, G. E.; HINDMAN, T. W.; LAKSMI, K. Machine vision detection parameters for plant species identification. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Precision Agriculture and Biological Quality**. [S.l.], 1999. v. 3543, p. 327–336.

MEYER, G. E.; NETO, J. C. Verification of color vegetation indices for automated crop imaging applications. **Computers and Electronics in Agriculture**, v. 63, n. 2, p. 282–293, 2008. ISSN 01681699.

MONTGOMERY, D. C. **Design and Analysis of Experiments**. [S.l.: s.n.], 2012. v. 2. 780 ST – Design and analysis of experiments. Adva p. ISSN 00401706. ISBN 0471316490.

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. Disponível em: <http://dx.doi.org/10.1016/j.patcog.2016.08.013>.

OHTA, Y.; KANADE, T.; SAKAI, T. **Color Information for Region Segmentation**. 1980. 222–241 p.

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.
- PETRO, A. B.; SBERT, C.; MOREL, J.-M. Multiscale retinex. **Image Processing On Line**, p. 71–88, 2014.
- POYNTON, C. **OpenCV: Color conversions**. 2018. Disponível em: <https://docs.opencv.org/3.1.0/de/d25/imgproc_color_conversions.html>.
- PRATT, W. K. **Digital Image Processing: PIKS Inside**. [S.l.: s.n.], 2001. v. 5. 738 p. ISSN 1940-6029. ISBN 0471374075.
- RAHMAN, Z.-u.; JOBSON, D. J.; WOODILL, G. a. Retinex processing for automatic image enhancement. **Journal of Electronic Imaging**, v. 13, n. 1, p. 100, 2004. ISSN 10179909.
- 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. **IEEE Transactions on Image Processing**, v. 21, n. 8, p. 3612–3623, 2012. ISSN 10577149.
- STANIKUNAS, R.; VAITKEVICIUS, H.; KULIKOWSKI, J. J. Investigation of color constancy with a neural network. **Neural Networks**, v. 17, n. 3, p. 327–337, 2004. ISSN 08936080.
- STEWART, B. L.; TIAN, L. F. Machine- vision weed density estimation for real-time, outdoor lighting conditions. v. 42, n. 6, p. 1897–1909, 1999.
- STEWART, B. L. et al. Reduced-dimension clustering for vegetation segmentation. **Transactions of the ASAE**, American Society of Agricultural and Biological Engineers, v. 47, n. 2, p. 609, 2004.
- TANG, L.; TIAN, L.; STEWART, 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.
- 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.
- TILMAN, D. et al. Global food demand and the sustainable intensification of agriculture. **Proceedings of the National Academy of Sciences**, National Acad Sciences, v. 108, n. 50, p. 20260–20264, 2011.
- TORRES-SÁNCHEZ, J. et al. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. **Computers and Electronics in Agriculture**, v. 103, p. 104–113, 2014. ISSN 01681699.
- UPCROFT, B. et al. Lighting Invariant Urban Street Classification. n. ii, 2014.

VAZQUEZ, J. et al. Color Constancy Algorithms: Psychophysical Evaluation on a New Dataset. **J. Imaging Sci. Technol**, v. 1, n. 3, p. 1, 2009. ISSN 10623701.

WEN-CHIANG, H.; CHWAN-HWA, W. Adaptive color image processing and recognition for varying backgrounds and illumination conditions. **Industrial Electronics, IEEE Transactions on**, v. 45, n. 2, p. 351–357, 1998. ISSN 0278-0046.

WEST, G.; BRILL, M. H. Necessary and sufficient conditions for Von Kries chromatic adaptation to give color constancy. **Journal of Mathematical Biology**, v. 15, n. 2, p. 249–258, 1982. ISSN 14321416.

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. ISSN 0001-2351.