



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA

ANDERSON PIRES ROCHA

**CLASSIFICAÇÃO DO ESTÁDIO DE MATURAÇÃO DE
TOMATES EM AMBIENTE PROTEGIDO POR MEIO DO
PROCESSAMENTO DE IMAGENS E LÓGICA FUZZY**

CAMPINAS

2019

ANDERSON PIRES ROCHA

**CLASSIFICAÇÃO DO ESTÁDIO DE MATURAÇÃO DE
TOMATES EM AMBIENTE PROTEGIDO POR MEIO DO
PROCESSAMENTO DE IMAGENS E LÓGICA FUZZY**

Dissertação apresentada à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Agrícola na Área de Máquinas Agrícolas.

Orientador: Prof. Dr. Angel Pontin Garcia

ESTE TRABALHO CORRESPONDE À
VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELO ALUNO
ANDERSON PIRES ROCHA, E
ORIENTADA PELO PROF. DR. ANGEL
PONTIN GARCIA

CAMPINAS

2019

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

R582c Rocha, Anderson Pires, 1977-
Classificação do estágio de maturação de tomates em ambiente protegido por meio do processamento de imagens e lógica fuzzy / Anderson Pires Rocha. – Campinas, SP : [s.n.], 2019.

Orientador: Angel Pontin Garcia.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Estufas. 2. Estufas para cultivo - Automação. 3. Sistemas embarcados (Computadores). 4. Casas de vegetação - Clima. 5. Casas de vegetação - Sombreamento. I. Pontin, Angel Garcia, 1978-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Classification of tomatoes maturation stage in green house using image processing and fuzzy logic

Palavras-chave em inglês:

Greenhouses

Greenhouses for cultivation - Automation

Embedded Systems (Computers)

Houses of greenery - Climate

Houses of greenery - Shading

Área de concentração: Máquinas Agrícolas

Titulação: Mestre em Engenharia Agrícola

Banca examinadora:

Angel Pontin Garcia [Orientador]

Barbara Janet Teruel Mederos

Eduardo Fernandes Nunes

Data de defesa: 14-01-2019

Programa de Pós-Graduação: Engenharia Agrícola

FOLHA DE APROVAÇÃO

Este exemplar corresponde à redação final da **Dissertação de Mestrado** defendida por **Anderson Pires Rocha**, aprovada pela Comissão Julgadora em 14 de janeiro de 2019, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

FEAGRI

Prof. Dr. Angel Pontin Garcia – Presidente e Orientador
FEAGRI/UNICAMP – Campinas

Profa. Dra. Barbara Janet Teruel Mederos – Membro
Suplente

FEAGRI/UNICAMP – Campinas

Faculdade de

Dr. Eduardo Fernandes Nunes – Membro Titular
UniMetrocamp/Wyden – Campinas

Engenharia Agrícola
Unicamp

A Ata da defesa com as respectivas assinaturas dos membros encontra-se no processo de vida acadêmica do discente.

AGRADECIMENTOS

A Deus, à minha família, pais, parentes e amigos.

Ao meu orientador, Prof. Dr. Angel Pontin Garcia, aos professores Inácio Del Faro, Barbara Teruel Mederos, Daniella Jorge de Moura, Raquel Goncalves, Stanley Robson de Medeiros Oliveira, Zigomar Menezes de Souza, Franciane Colares Souza Usberti, Mauro Jose Andrade Tereso, Thais Queiroz Zorzeto Cesar.

Aos colegas Guilherme Bezzon, Cláudio Umezu, Hugo Rafacho Fernandes, Fabrício Soares, Ivan Camilo Arbeláez Ruiz, Cezario Benedito Galvão, Rodrigo Leme, Zózimo Ramonda, Leandro Morais, Antonio Henrique e Antonio Gallinucci.

RESUMO: O emprego de sistemas computacionais na agricultura auxilia a automação de processos e tarefas aplicadas nesta área, objetivando a inspeção e análise, por exemplo, de frutos. No entanto, obter informações do estado da cultura se mostra um problema complexo, seja em cultivos realizados em campo aberto, seja em casas de vegetação. Neste contexto, o objetivo geral deste trabalho foi o de desenvolver um sistema de classificação de frutos, não destrutivo, para tomates (*Solanum Lycopersicum*) da variedade Santa Cruz Kada Gigante, durante período de safra, em uma casa de vegetação. Neste projeto são utilizados recursos de visão computacional, onde foram obtidos dados sobre a cor do fruto. Após a captura das imagens foram realizadas análises, por meio da segmentação, para a identificação da cor, sua área de cobertura e da classificação dos frutos, por meio da lógica difusa (*fuzzy*) e da discretização em volume do espaço de cor (*voxel*). Para isso utilizou-se padrões específicos que representem o estágio de maturação do fruto, segundo as normas existentes. Com isso, o sistema de identificação foi capaz de realizar a aquisição das informações, e definir os estádios de amadurecimento do fruto, em função de parâmetros estabelecidos previamente. A exatidão do sistema foi avaliada para o aprimoramento e mitigação de erros em cada nível da classificação.

Palavras-chave: Cor, Sistemas Embarcados, Casas de vegetação

ABSTRACT: The use of computational systems in agriculture helps the automation of processes and tasks applied in this area, aiming at the inspection and analysis, for example, of fruits. However, obtaining information on the state of the crop is a complex problem, whether in open field crops or in greenhouses. In this context, the general objective of this work was to develop a non – destructive fruit classification system for tomatoes (*Solanum Lycopersicum*) of the Santa Cruz Kada Gigante variety during a harvest period in a greenhouse. In this project are used computational vision resources, where data about the color of the fruit were obtained. After the images were captured, they were analyzed by means of the segmentation, to identify the color, its area of coverage and the classification of the fruits, by means of the fuzzy logic and the volume discretization of the color space (voxel). For this, specific patterns were used that represent the maturation stage of the fruit, according to the existing norms. With this, the identification system was able to perform the information acquisition, and to define the maturation stages of the fruit, according to previously established parameters. The accuracy of the system was evaluated for the improvement and mitigation of errors at each classification level.

Keywords: Color, Embebed Systems, Green House

LISTA DE ABREVIATURAS E SIGLAS

USDA – Departamento de Agricultura dos Estados Unidos

CCD – Dispositivos de Carga Acoplada

CMOS – Semicondutor de metal-óxido complementar

RGB – Red (Vermelho), Green (Verde), Blue (Azul)

HSV – Tom, Saturação, Intensidade

HUE – Luminância de cores

LAB – Luminosidade, Verde/Vermelho, Amarelo/Azul

Lógica Fuzzy – Lógica difusa, nebulosa

FFMPEG – Conversor de vídeo por linha de comando

AVI – Audio Vídeo Interleave ou formato de áudio e vídeo

JPG – Joint Photographics Experts Group ou formato de imagem

OTSU – Método de segmentação de Nobuyuki Otsu

ROC – Curva de características operacionais do sistema

GPU – Unidade de Processamento Gráfico

RF – Random Forest ou Árvore de decisão

MLP – Multilayer Perceptron ou Percepção Multi Camada

Cloud computing – Computação em nuvem

SUMÁRIO

1. INTRODUÇÃO.....	9
3. HIPÓTESE.....	10
3. OBJETIVOS.....	11
4. REVISÃO BIBLIOGRÁFICA.....	12
5. MATERIAIS E MÉTODO.....	26
6. RESULTADOS E DISCUSSÕES.....	41
7. CONCLUSÕES.....	48
8. REFERÊNCIAS BIBLIOGRÁFICAS.....	49
APÊNDICE.....	58

1. INTRODUÇÃO

A classificação de frutos, segundo estádios de maturação pode ser realizada de forma manual, visual, por meio de cartas de classificação, dentre outros métodos, ou ainda pela experiência prática. Esta interpretação manual é subjetiva, podendo ser afetada devido ao cansaço, bem como influenciada pela presença de outras cores durante a análise.

Em grandes fazendas e casas de vegetação, esta tarefa demanda tempo e mão de obra, sendo muito onerosa. Uma automatização do processo de avaliação da maturação e sua classificação, pode oferecer um ganho para o produtor agrícola, sendo que a utilização de sistemas especialistas poderá eliminar as inconsistências na estimativa de maturação, decorrida da avaliação manual.

O emprego de recursos computacionais para o processamento de imagens tem sido amplamente adotado para avaliações externas em frutos, determinando tamanho, forma, cor e defeitos, durante a pré e pós-colheita, no entanto, ainda estão em crescente desenvolvimento e em alguns casos, podem ser considerados escassos. Nestes processamentos, assumem-se as características do olho humano, trabalhando com o significado das informações, para classificar objetos ou apenas para a comparação de componentes presentes nas imagens.

Para a identificação da cor dos frutos no ambiente em que se encontram, na etapa pré colheita, existem algoritmos e sistemas de processamento de imagens desenvolvidos para este fim, apresentando exatidão, mesmo em ambientes com condições de luminosidade diversas, ou ainda em espaços de cores variados, porém, os métodos de calibração e aquisição de imagens não são claros ou não existem, bem como a metodologia de análise dos resultados.

Neste trabalho, será apresentada e testada uma metodologia para a classificação da cor de tomates, identificando seus estádios de maturação, por meio de padrões pré-determinados e por imagens coletadas em períodos ou em tempo real, sendo capaz de determinar os estádios de maturação de tomates, na planta, em uma casa de vegetação, utilizando normas de classificação.

3. HIPÓTESE

A hipótese deste trabalho é que o sistema de classificação proposto, baseado no processamento de imagens e lógica fuzzy é capaz de estimar o estágio de maturação de tomates conforme estabelecido pela USDA.

3. OBJETIVOS

O objetivo geral deste trabalho visa determinar o estágio de maturação de tomates em um ambiente protegido (casas de vegetação), utilizando técnicas de processamento de imagens.

Como objetivos específicos, tem-se:

1. Realizar a aquisição das imagens, por meio de uma câmera RGB;
2. Segmentar imagens, separando o tomate do fundo ou ambiente;
3. Determinar o centro de massa dos frutos nas imagens;
4. Definir a região de interesse ao redor do centro de massa;
5. Realizar a classificação pixel-a-pixel das cores;
6. Utilizar a avaliação espacial dos *pixels*, por meio de *voxels*;
7. Obter as cores de interesse para a classificação dos estádios;
8. Implementar um classificador *fuzzy* de múltiplas entradas e uma saída;
9. Estabelecer as regras para a classificação dos estádios de maturação, utilizando a tabela USDA;
10. Comparar os resultados obtidos da classificação humana, com o classificador artificial;
11. Construir índices de acertos e erros baseados em uma matriz de confusão e gráfico das características operacionais do sistema;
12. Avaliar os resultados do classificador proposto, com a literatura, verificando sobreajustes nos resultados e baixa exatidão.

4. REVISÃO BIBLIOGRÁFICA

A classificação de frutos é destinada ao mercado ou a produção alimentícia. Para os produtores nacionais os frutos são classificados de acordo com o mercado local ou distante (Denis et al., 2006). Os atuais classificadores automatizados, baseados em processamento de imagens, avaliados por Ferrari et al., (2006), quando calibrados por metodologias como a proposta por Wilson et al., (2017), diferenciam até 24 tonalidades de cores em frutos, permitindo uma maior gama de seleção, distribuição e envase de produtos mais homogênea.

Na classificação manual, as cartas de cor utilizadas, são baseadas na USDA, adotada por Goel e Sehgal, (2015) e outros autores, a qual classifica seis estádios de maturação (figura 1).

Figura 1: Referência para a classificação de tomates em carta fornecida pela USDA



Fonte: USDA

Embora existam outras cartas e interpretações para diferentes países, a USDA é amplamente citada, em alguns casos a escala de classificação inglesa, é referenciada, como visto em Roy et al., (2017), mas não utilizada.

Não há unanimidade na quantidade de estádios para a classificação, mesmo utilizando-se a carta USDA, Devalatkar et al., (2016) avaliam apenas dois estádios e Ting et al., (2009), três estádios, concluindo que esta quantidade de índices é insuficiente para classificar a maturação de tomates.

Para a análise computadorizada, em ambientes abertos, fora dos ambientes controlados, são avaliados frutos considerados no estágio verde maduro por Pérez et al., (2017) ou vermelho maduro em Arefi et al., (2011), devido à complexidade das imagens nestes locais. Roy et al., (2017), elaboram um novo método de classificação

de frutos na planta, no entanto, todo o cacho de tomates é retirado da planta e analisado em laboratório.

Na classificação automatizada de frutos ou de seus estádios de maturação, diversos autores descrevem metodologias que apresentam exatidão entre 72% de Goel e Sehgal (2015) e 96% de Zhao et al., (2016), em alguns casos o sistema se apresenta ineficiente, como verificado por Schillaci et al., (2012). Uma análise destes dados, não auxilia diretamente na escolha dos métodos a serem utilizados no desenvolvimento do sistema de classificação pretendido, devido à falta de diversos parâmetros, como por exemplo, a configuração do equipamento de aquisição de imagens, os aspectos ambientais e detalhes da cultura avaliada.

A classificação dos estádios de maturação, visa a identificação das cores apresentadas pelos frutos do tomateiro, entre o estágio verde maduro (USDA, estágio 1), até o ponto de colheita considerado limite (USDA, estágio 6), não tendo como objetivo a distinção entre espécies de tomate, apresentadas por Preczenhak et al., (2014), ou ainda, da identificação morfológica dos objetos, de acordo com a análise de Dreuzyb et al., (2016).

Para os anos compreendidos entre 2006 e 2011, são apresentadas metodologias de processamento de imagens em Barrios et al., (2011), para a classificação de frutos, fator importante, pois, a principal base de trabalhos consultada apresenta pesquisas a partir do ano 2008, como no sistema de classificação de frutos proposto por Bossard et al., (2008), explorando aspectos cognitivos da visão de máquina.

Fora desta linha de tempo e fonte, são encontradas citações de trabalhos da década de 90, como de Jahns et al., (1998), em alguns casos, como no livro de Rich (1988), são apresentadas pesquisas realizadas desde a década de 60.

Algumas técnicas de classificação, baseadas na análise instrumental, como aquela apresentada por Zhang et al., (2014), tem sido muito utilizadas, porém, somente utilizando sistemas computacionais de processamento de imagem e comparações. Recentemente duas novas técnicas de classificação surgiram, utilizando redes neurais em Pabico et al., (2015) e lógica fuzzy Goel e Sehgal (2015), permitindo ao computador tomar decisões, executar atividades mais complexas, como a colheita de frutos apresentada por Kondo et al., (2009).

Alguns dos autores pesquisados apresentam um fluxo para o processo de classificação da maturação por meios colorimétricos, outros consideram esta classificação como fator que determina a qualidade do fruto, como Elings et al., (2004), outros relacionando os estádios de maturação com composições químicas, verificado por Weingerl et al., (2015) ou imagens estruturais internas evidenciado por Zhans et al., (2011).

De maneira geral, a classificação de frutos, fornece ao sistema computacional, parâmetros para a identificação das informações do mundo exterior, desta forma, o computador será treinado para possuir uma inteligência capaz de interpretar significados descritos em Pérez et al., (2010) e tomar decisões similares aos seres humanos, caracterizados em Gu et al., (2017).

Para que o cérebro eletrônico realize sua tarefa com eficiência, ele necessita de informações sensoriais dos frutos, similarmente aos cinco sentidos humanos, sendo eles, táteis explorados por Sirisomboon et al., (2012), auditivos (sonoros) avaliados por Sanchez et al., (2009), olfativos descritos Gomes et al., (2006), palatáveis em Beullens et al., (2008) e visuais apresentados por Arefi et al., (2011).

Além destas características, outras são exploradas, sempre relacionadas aos estádios de maturação, como a força necessária para o desprendimento de frutos, avaliada por Reis et al., (2015), ou a densidade e textura da superfície do fruto, verificada por Lien et al., (2008). Atualmente, a exploração destas características permitem a criação de equipamentos como apresentados pela Universidade de Cornell, por Zhao et al., (2016), tratando-se de sistemas automatizados que realizam diversas operações em fazendas, dentre elas, a condução de culturas frutíferas.

Como forma de interpretar corretamente todas estas informações de maneira não binária, são utilizadas técnicas de aprendizado de máquina em Bendary et al., (2015) e inteligência artificial em Zhao et al., (2016), reproduzindo algumas capacidades decisórias humanas, principalmente na área de processamento de imagens.

As condições de análise da maturação são baseadas em diversos métodos descritos por Chen et al., (2002), caracterizados como destrutivos ou não destrutivos. O método de aquisição da informação visual do fruto, por meio do sensoriamento,

trabalha com a percepção das cores verificadas por Hamuda et al., (2017), com estímulos simples, monocromáticos de Cozmuta et al., (2016) ou em diferentes espectros da luz, visível estudados por Senthinath et al., (2016) e invisíveis ao olho humano, avaliados por Radzevicius et al., (2016).

De posse da informação digital do fruto, esta será analisada, conforme o ambiente em que se baseia, em laboratório, são capturadas imagens onde são focalizados apenas os frutos, visto em Zaborowicz et al., (2017). Nas tomadas de imagem mais abertas, são utilizados fundos, contendo cores ou texturas simples, apresentado por Roy et al., (2017), em sua aquisição de imagens.

Esta escolha de objetos presentes nas imagens, é um recurso auxiliar para a análise da cor e sua identificação, caso utilize a segmentação de cores, por meio da avaliação de histograma, apontada por Valera et al., (2014), bem como, a manipulação dos *pixels* presentes nas imagens elaborada por Zhao et al., (2016), ou a sua supressão, por meio de limiares de cor avaliados por Senthilnath et al., (2016) e Segmentação Otsu, descrita por Xiang et al., (2014).

As metodologias de Machine Learning – Aprendizado de máquina, supervisionado de Bendary et al., (2015), ou os sistemas de classificação por meio da lógica fuzzy de Goel e Sehgal (2015), necessitam que as informações a serem analisadas sejam inseridas manualmente. Em sistemas não supervisionados, a inteligência artificial escolherá qual informação será utilizada para a análise e ponderação de resultados, em ambos os casos, a informação é proveniente do sistema de captura de imagens.

Quanto ao equipamento utilizado não há um consenso, sendo empregados principalmente câmeras com sensores CCD em Cheng et al., (2015) e CMOS, em Gongal et al., (2015). Sua disponibilidade no mercado ou tecnologia associada é um fator de escolha para Goel e Sehgal (2015).

São utilizados equipamentos monoculares em Linero et al., (2017), binoculares em Rong et al., (2014) ou tecnologias de sensores de profundidade, RGB e Infravermelho em Luna et al., (2016). Em decorrência desta escolha, cada equipamento apresentará a informação da imagem em representações de cores (espaços de cor) diferentes, como verificado por Roy et al., (2017).

Em alguns casos, a imagem original é convertida para outro espaço de cor, realizado por Bendary et al., (2015), objetivando uma representação abrangente das cores descrito por Roy et al., (2017), ou que permitam uma modelagem matemática específica das cores, apresentado por Lana et al., (2005).

Quando considerada a aquisição das imagens por meio de sensores tri-estímulos RGB ou LAB, a identificação dos estádios de maturação ocorre pela análise da proporção nos componentes de cor, em Mansor et al., (2015), pela diferenciação de dois ou mais componentes de cor, em Goel e Sehgal (2015), ou ainda, pela elaboração de novos índices de avaliação, como utilizados por Camelo et al., (2004).

Autores como Camelo et al., (2004), que avaliam a maturação dos frutos, baseadas em instrumentos como colorímetros e Roy et al., (2017), por meio de imagens hiperespectrais, utilizam e descrevem os métodos de calibração das cores, porém, este método não é muito claro nas metodologias de processamento de imagens.

Para a aquisição de imagens em ambiente protegido, alguns autores levam em consideração as propriedades espectrais da estufa, como Enriquez et al., (2013), bem como possíveis distorções ocorridas nas lentes ópticas dos equipamentos, verificados por Ting et al., (2011). Para Lu et al., (2016), são necessários procedimentos de calibração na morfologia dos objetos capturados e analisados digitalmente.

São apontados dois métodos de calibração, pela presença de uma carta de cor, conhecida como Pantone, apresentada por Roy et al., (2017) ou pela presença de objetos com formas e tamanhos conhecidos, como as esferas presentes em Lu et al., (2016).

Muitos autores utilizam para calibração da classificação, os próprios frutos, porém, estes apresentam diferentes níveis de cores, segundo as espécies de tomate avaliados por Stinco et al., (2012). O mesmo autor apresenta escalas de maturação diferente, por espécie de tomate ou ainda, ao comparar-se uma mesma espécie de tomates entre autores, os valores médios de cor informados são discrepantes.

Sengupta et al., (2013) relata que as classificações devem ocorrer mesmo em condições variadas de iluminação, no entanto a Hunter Labs, esclarece que para avaliações de cor eficientes, a fonte de iluminação, ou iluminante deve ser padronizada. Schifferstein et al., (2017) descreve estes detalhes, para a quantidade de

lâmpadas utilizadas, potência, tecnologia, temperatura da cor, distância com relação ao fruto, para somente após esta configuração, realizar suas aquisições.

Em seus estudos, Denis (2008), relata que as medidas perceptíveis procuram descrever atributos genéricos das cores. Dentre estes tipos de atributos que fornecem a percepção da sensação de luz esta a luminância, ou HUE, medida do nível da quantidade de energia emitida por uma fonte de luz, percebida por um observador. Em seus estudos Bendary et al., (2015), utiliza a luminância para a determinação das cores, para a classificação de tomates.

Como visto em Bendary et al., (2015), a classificação dos frutos deve ser eficiente, desta forma. A escolha dos parâmetros de aquisição para a classificação dos frutos pode ser sintetizada conforme a tabela 1.

Tabela 1: Parâmetros para aquisição de imagens para a classificação de frutos

Característica 1	Característica 2	Objetivo
Tipos de ambientes	Tipos de equipamentos	Espaço de cor
Variedade do fruto	Iluminante	Calibração
Complexidade da imagem	Espaço de cor	Segmentação da imagem
Número de amostras	Números de indivíduos	Modelo matemáticos

Assim como a quantidade de estádios, o número de imagens para aquisição e processamento, visando a classificação, varia entre os autores, são utilizadas 90 imagens em Goel e Sehgal (2015) e 250 imagens em Bendary et al., (2015), não sendo informado, na maioria dos casos, o formato da imagem, apenas a resolução.

O computador permitirá a repetibilidade das análises e tomada de decisão eficiente, uma vez que as condições de classificação sejam especificadas, visto que, os resultados obtidos na classificação manual, estão suscetíveis ao cansaço humano, apontado por Goel e Sehgal (2015) e às diferentes interpretações sensoriais citadas por Mendoza et al., (2006), principalmente nos ambientes em larga escala de produção agrícola.

Para a classificação das informações, tanto a lógica clássica é utilizada, como a lógica fuzzy, neste sentido, classificadores especialistas foram estudados em 2008 por Sanchez et al., (2008), assim como técnicas de análise para avaliação do estágio de maturação em Lee et al., (2008).

A Lógica Fuzzy, foi estudada em Zang et al., (2009), para utilização em sistemas decisórios e desde 2008 para a classificação de aspectos subjetivos em frutos por Kavdir et al., (2008). Para a estimativa da data da colheita, foi verificada por Mallomzadeh et al., (2008), não obstante, as técnicas de processamento de imagens por comparação ainda são estudadas e aplicadas atualmente, como a classificação de cores de tomates em Devalatkar et al., (2016), detecção de cores em tomates de Bharambe et al., (2016) e a verificação do estado do tomate de Scholar et al., (2016).

Para a construção de um classificador *fuzzy*, os trabalhos citados anteriormente não trazem referências objetivas, sobre os parâmetros de configuração, faltando assim, informações sobre as funções de pertinência, seus efeitos sobre a ponderação dos resultados, bem como o algoritmo utilizado como base para a defuzificação ou computação.

Em Garcia (2011), Soares (2015) e Fernandes (2017), além dos parâmetros anteriores, são apresentadas as matrizes utilizadas para a construção das regras *fuzzy*, bem como a padronização dos valores de entradas e saída do sistema, assim sendo, estes trabalhos fornecem as condições suficientes para a implementação do sistema de forma consistente.

Goel e Sehgal (2015), Mansor et al., (2015), seguem linhas de raciocínio diferentes, bem como apresentam resultados diversificados. No último caso, a contribuição encontrada foi a comparação dos resultados provenientes de parâmetros de configuração *fuzzy* diferentes para a classificação dos frutos, apresentando aquele considerado pelos autores o mais exato.

Dorado et al., (2016), realizou experimentos de classificação, comparando os algoritmos *fuzzy*, baseados na técnica Mamdani e técnica Sugeno, concluindo que estes poderão ser utilizados em sistemas de classificação de frutos, ainda fornecendo indícios de que o tipo de implementação, influencia nos resultados das classificações.

As técnicas que resultam em classificações multiclasse, tem seus resultados avaliados por ferramentas específicas, são utilizadas em Mansor et al., (2015) para a avaliação da classificação em três categorias de frutos, imaturos, indefinidos e maduros. Em Goel e Sehgal (2015), é apresentada uma classificação geral, de 94%, não específica às categorias de estádios avaliados. Nos autores que trabalharam com a análise por segmentação a avaliação dos resultados não é quantitativa, apenas qualitativa.

Na literatura, a classificação de frutos baseada na norma USDA, ocorre manualmente, sendo preliminar ao processo de classificação digital, como apresentado por Goel e Sehgal (2015). Após esta etapa os frutos serão avaliados por processamento de imagens e os valores numéricos das cores, representativos aos estádios, serão utilizados nas classificações automatizadas, como visto em Mansor et al., (2015).

Goel e Sehgal (2015), Mansor et al., (2015), Dorado et al., (2016), Arefi et al., (2011), obtêm, por métodos similares, os valores médios de uma determinada cor para seus sistemas de classificação e segmentação de imagens. No entanto, na avaliação da carta USDA, percebe-se a existência de índices indicativos dos estádios de maturação, expressos conforme a tabela 2:

Tabela 2: Proporcionalidade das cores de acordo com o estágio de maturação dos frutos

Estádio	Condição (%)
Estádio 1	Fruto totalmente verde-escuro ou claro
Estádio 2	Até 10 da superfície é amarela, rosa ou vermelha
Estádio 3	Entre 10 e 30 da superfície é amarela, rosa ou vermelha
Estádio 4	Entre 30 e 60 da superfície é rosa ou vermelha
Estádio 5	Entre 60 e 90 da superfície é rosa ou vermelha
Estádio 6	Fruto totalmente vermelho ou com índice superior a 90

Na carta USDA estes índices geram uma interpretação subjetiva, nas atualizações desta carta, providas pela Florida Tomates, Lagorio e outros, além dos índices anteriormente citados, atualizam-se as imagens de referência dos frutos, para

melhor compreensão sobre a manifestação das cores. Em alguns casos, o fruto é apresentado em uma vista lateral, ao contrário das vistas superior e inferior presente na carta USDA.

O princípio de quantificação de cores é utilizado na área médica por Alfred et al., (2017), para identificação de melanomas e na agricultura por Liu et al., (2017). Para o design de produtos, é apresentado por Mylonas e MacDonald (2017), sendo encontrados para avaliação de frutos e seus estádios de maturação em Sanaelfar et al., (2015).

Baseado-se em alguns destes métodos, a avaliação da proporção de cores, poderá ser realizada, inicialmente, de duas formas. A primeira pela conversão da amostra de imagem do fruto em 8 bits de cores e sua análise por meio da Fração de Área – *Area Fraction*. A segunda opção, se dá pela segmentação em três imagens, representativas de cada canal e a avaliação da área de *pixels* destas, pelo mesmo método de análise.

Outra metodologia está baseada na segmentação proposta por Devalatkar et al., (2016), onde cada pixel na imagem é avaliado para identificar se um fruto é verde ou vermelho. Bharambe et al., (2016), além da segmentação anterior, incluem uma análise proporcional e estatística das cores, onde são identificados os índices de cor amarela nos frutos.

Em Valera et al., (2014), a classificação de frutos ocorre por meio da análise dos histogramas das cores. As amostras de imagens são submetidas ao algoritmo, para levantamento dos valores de cor em cada pixel na imagem. Estas informações são obtidas automaticamente pelo algoritmo, levando-se em conta a análise em escala de cinza e os três canais de cor, na avaliação de frutos realizada por Lino et al., (2008).

Em Mollazade et al., (2012), realiza-se a segmentação das imagens e quantificação das amostras de cores, para determinar a porcentagem de cobertura nos frutos. As amostras de imagens são submetidas ao algoritmo para levantamento dos limiares de segmentação e quantificação das cores no fruto. Neste processo, uma área da imagem é analisada por meio de limiar – *threshold*, destacando-se as cores, que serão convertidas para preto e branco, seguindo para a análise posterior da área preenchida pelas cores.

Com o intuito de identificar a cor em tomates, Bharambe et al., (2016), criaram um equipamento dotado de câmera e transportador mecânico dos frutos classificados, a técnica de segmentação das imagens trabalha com os três componentes de cor, separando-os e realizando uma combinação destes, por meio de limiares de cor, criando uma máscara que identifica quatro categorias de frutos, sendo: vermelho, laranja, amarelo e verde. Comparando-se as quatro imagens com aquela que apresenta maior índice de cores, é encontrado o estágio de maturação dos frutos.

Pesquisas realizadas nas áreas de análise foliar de plantas, identificação de doenças em frutos, são baseadas na determinação de padrões e correlação com o agente patológico, porém, ao contrário da utilização de valores numéricos de cores, apresentado por Falomir et al., (2014), utilizam uma nomenclatura específica de cor, a qual ordena os valores numéricos a partir do cubo RGB, sendo conhecidas como cores seguras que poderão ser reproduzidas, impressas e analisadas.

Liu et al., (2017), utilizam esta técnica para a classificação de texturas em folhas, analisando o histograma das imagens em busca de cores indexadas.

A USDA, além dos índices numéricos de área para a cor, apresenta uma indexação das cores, baseadas em suas nomenclaturas, sendo: *GREEN*, *LIGHT GREEN*, *DARK GREEN*, *TANNISH*, *YELLOW*, *PINK*, *PINKISH*, *LIGHT RED* e *RED*.

Baseando-se em Broek et al., (2008), encontram-se os seguintes valores RGB para estas cores na tabela 3.

Tabela 3: Relação das nomenclaturas das cores e seus valores RGB. Adaptado de Broek et al., (2008)

Cor	Red	Green	Blue
Green	0	128	0
Light Green	144	238	144
Dark Green	0	100	0
Tannish	210	180	140
Yellow	255	255	0
Pink	255	192	203
Pinkish	231	218	218
Red	255	0	0

Além destas cores, catálogos como o PANTONE ou MUNSSELL, que visam a reprodução das cores de maneira digital ou para a confecção de produtos, apresentam as seguintes cores, conforme a tabela 4.

Tabela 4: Relação das nomenclaturas das cores e seus valores RGB

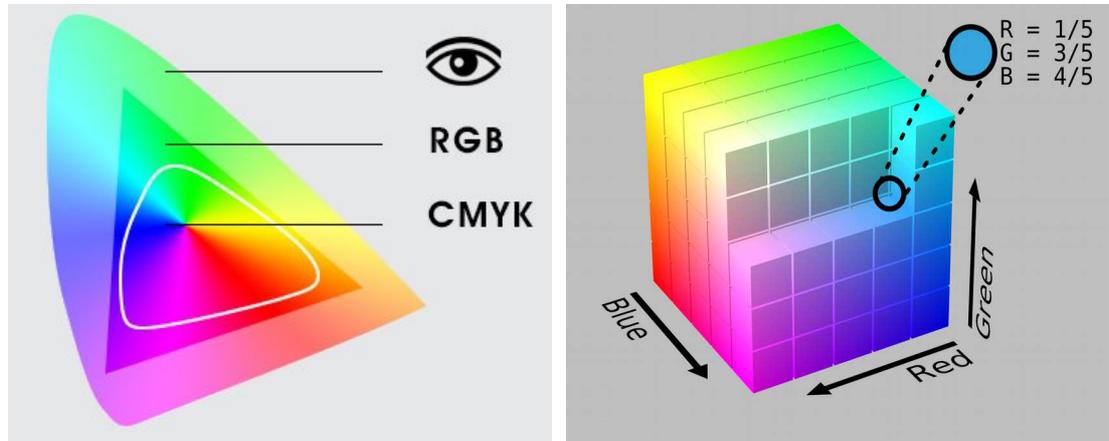
Cor	Red	Green	Blue
Tomate	255	99	71
Dark Red	139	0	0

Desta forma a cor Tomate é composta por 100% de vermelho, 39% de verde e 28% de azul. Além das cores anteriormente apresentadas, existem variações, para o verde, amarelo, rosa, e de vermelho.

Existem outras indexações, ultrapassando 500 nomes, sendo mais utilizadas para a representação digital das cores na internet.

Denis (2008) em sua dissertação, além de diversas explanações sobre a percepção das cores pelo olho humano, apresenta o espaço de cor RGB, tanto no padrão de duas dimensões (figura 2a), como em três dimensões, conhecido como cubo RGB (figura 2b), como a percepção computacional do espaço de cores.

Figura 2: (a) Representação 2D do espaço RGB. (b) Representação 3D do espaço RGB



(a) - Fonte: Adaptado de Denis (2008)

(b) - Fonte: Adaptado de Denis (2008)

Em softwares, como o *Matlab*, a representação padrão do cubo RGB, possui apenas 64 cores, normalizadas (0 a 1). Caso este cubo possua apenas 8 cores em uma análise de cor, estas serão pertencentes à escala de cores cinza. Considera-se, neste caso, o cubo RGB padrão, conforme a palheta presente na figura 3. Outras estão disponíveis, sendo utilizadas conforme o objetivo das análises ou utilização de outros espaços de cor.

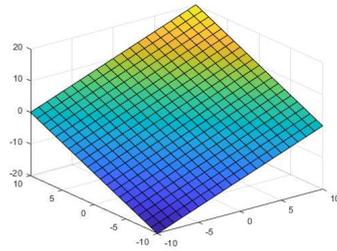
Figura 3: (a) Paleta de cores padrão do Matlab



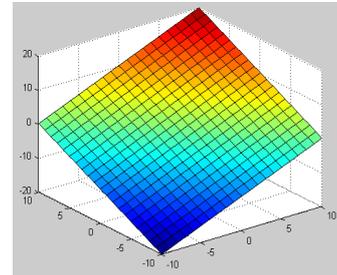
Fonte: Mathworks

Estas cores poderão ser analisadas pelo método de coordenadas ou Mapa de Cores, conforme a figura 4, utilizada por Moares et al., (2017), para a avaliação da produção de carne bovina.

Figura 4: (a) Sessão isolada da cor presente no Cubo RGB. (b) Cores do cubo RGB



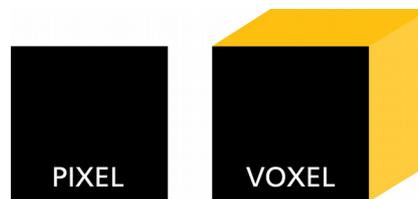
(a) - Fonte: Mathworks



(b) - Fonte: Mathworks

Em seu trabalho na área de processamento de imagens e avaliação da maturação de frutos, Lee et al., (2007), não apresentam análises por superfícies ou faces do cubo RGB, com mapeamento de *pixels*, utilizam o conceito de *voxel* (figura 5), atualmente conhecido como pixel 3D ou *pixel* volumétrico, considerando este método mais exato para a análise da distribuição de cores.

Figura 5: Diferenciação gráfica entre pixel e voxel

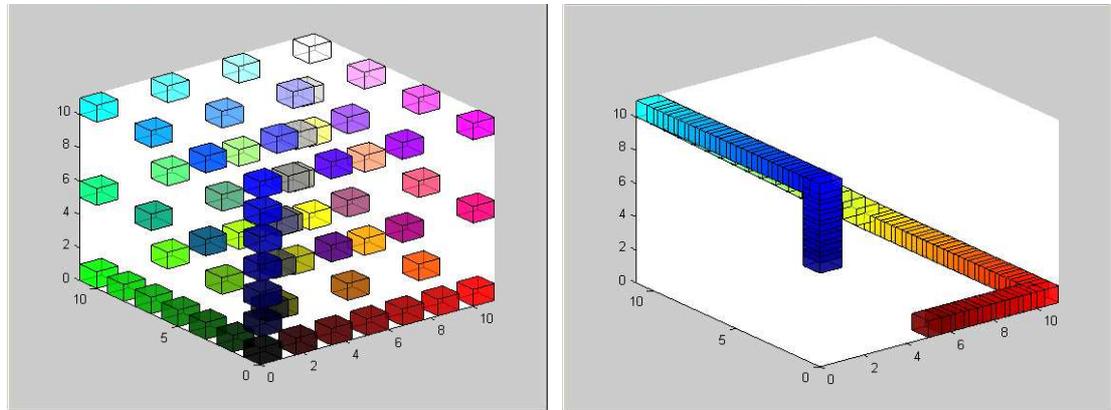


Fonte: Shailesh Kottal, D.D.S.

Esta técnica é utilizada por Maani et al., (2017), para a análise de texturas dos *voxel*, como forma de identificar regiões cerebrais, algo similar apresentado por Whitwell et al., (2017), para a identificação de atividades cerebrais. Em frutos, o *voxel* é utilizado na análise do estágio de maturação de tomates, por meio de imagens provenientes da ressonância magnética, apresentada por Zhanga et al., (2017).

Ao utilizar as técnicas de *COLORCUBE* (figura 6a) e *COLORMAP* (figura 6b) no software *Matlab*, os resultados não refletem a representação integral do espaço de cor RGB, proposta por Zhang et al., (2014).

Figura 6: Representação do espaço de cor RGB. (a) Técnica Colorcube. (b) Técnica Colormap.



(a)

(b)

Desta forma, em Zhang et al., (2014), é encontrada a representação completa do cubo RGB, contendo $256 \times 256 \times 256$ cores, simplificadas para $4 \times 4 \times 4$, com objetivo de otimizar a análise de cor proposta pelos autores.

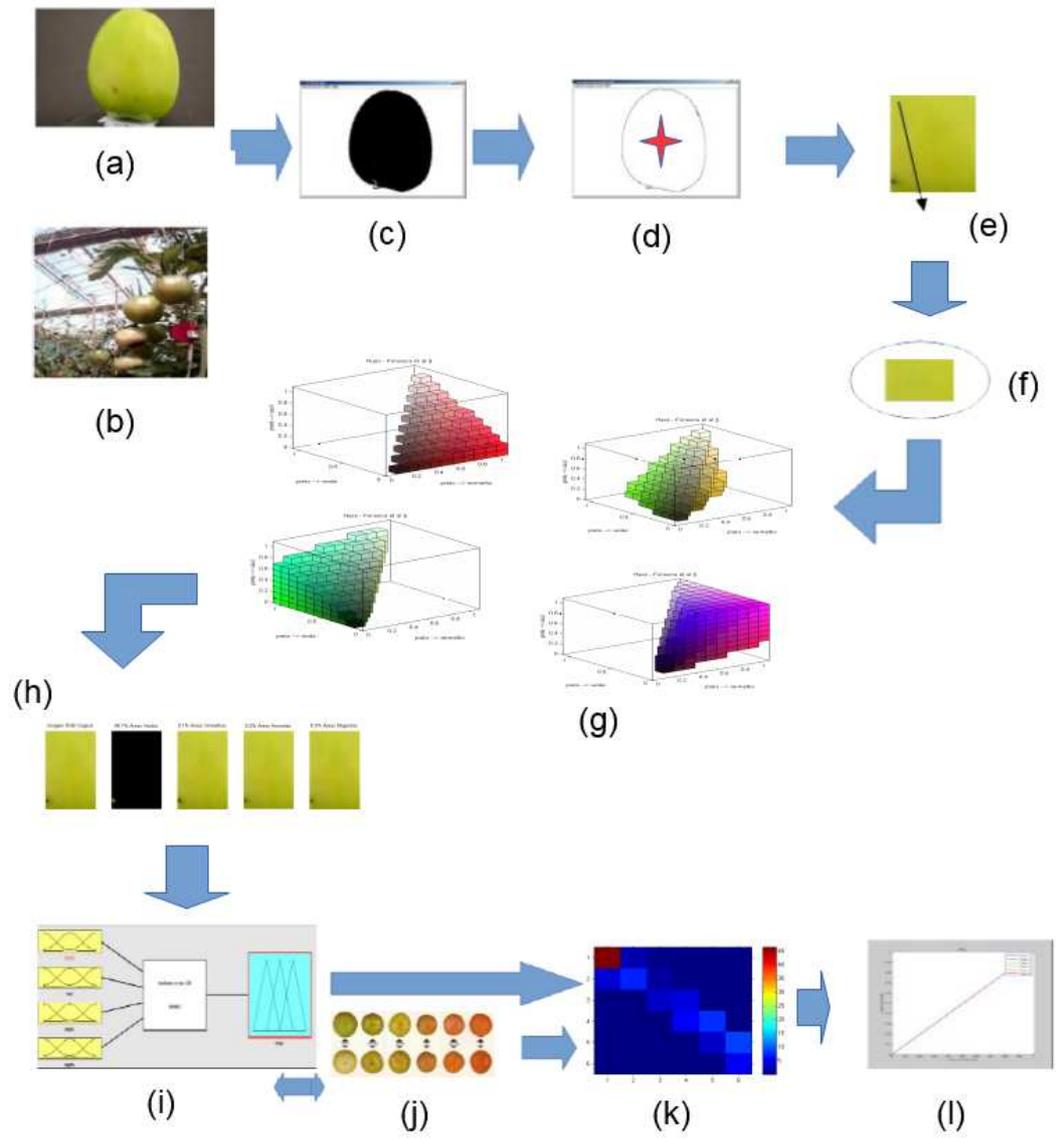
Outra forma de discretização das cores é apresentada por Ysof et al., (2010), na utilização da lógica fuzzy para o controle de fontes luminosas, similarmente desenvolvido por Hassan et al., (2012), ou ainda pelos estudos apresentados por Boaventura et al., (2006) na classificação da cor superficial da pele humana.

Por fim, têm-se a avaliação dos resultados das avaliações, para Ling, (1995), entender e prevenir *overfitting* (sobreajuste) é uma questão muito importante no projeto e na implementação e aplicação de inteligências artificiais, desta forma, relata que a presença e ausência de *overfitting*, depende de como o erro de teste é medido, e que não há *overfitting* em termos do erro de classificação (erros de nível simbólico). Demonstram que, em termos do erro de classificação, o *overfitting* ocorre em certas representações utilizadas para codificar os atributos discretos, projetando funções booleanas simples, com um raciocínio claro e apresentam resultados experimentais para apoiar estas afirmações. Em seu livro, Silver (2013), trata do sobreajuste dos dados na análise estatística, enfatizando que atualmente os sistemas têm adotado soluções muito específicas para problemas gerais, tornando a previsão de dados piores, quando a análise é muito ou pouco ajustada, ou seja, incluindo nos resultados finais, possíveis ruídos na informação.

5. MATERIAIS E MÉTODO

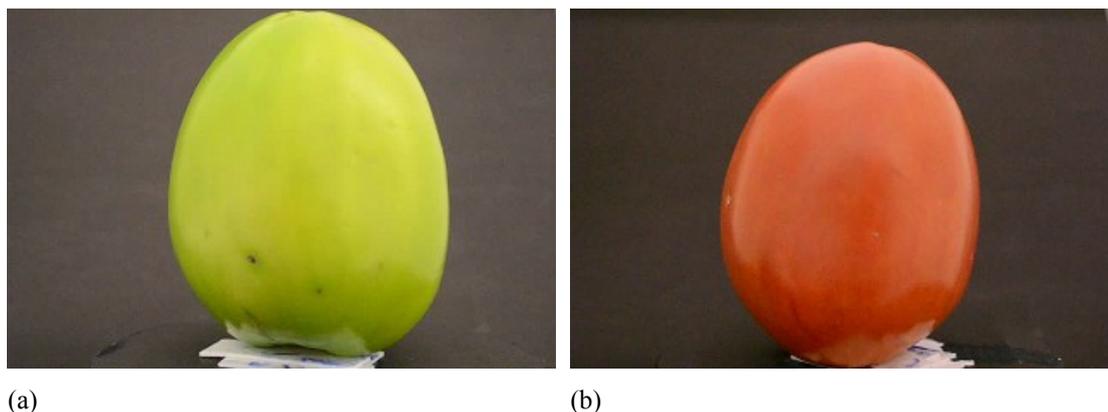
Para a classificação do estágio de maturação de tomates utilizou-se o método apresentado na figura 7. Observa-se o fluxo utilizado para a classificação dos tomates, desde a aquisição das imagens, por meio de uma câmera RGB, até a sua classificação final, seguindo rotinas específicas para imagens adquiridas em laboratório, conforme a figura 7(a) ou em uma casa de vegetação, figura 7(b). Inicialmente realizou-se a captura das imagens, posteriormente, o processo de segmentação, separando o tomate do fundo ou ambiente, figura 7(c) e determinando-se o centro de massa, figura 7(d). Ao redor deste ponto é definida a região de interesse, figura 7(e) e aplica-se o processo de classificação pixel-a-pixel das cores, figura 7(f). Utilizando-se a avaliação espacial dos *pixels*, por meio de *voxels*, figura 7(g), são obtidas as cores de interesse. Com a imagem categorizada, as quatro cores resultantes e suas respectivas áreas, figura 7(h), são destinadas à entrada do classificador *fuzzy*, figura 7(i), que contém as regras para a classificação dos estágios de maturação, utilizando a tabela USDA. Por fim, esta classificação é comparada com os resultados obtidos pela classificação humana, figura 7(j), gerando um índice de acertos e erros baseados em uma matriz de confusão, figura 7(k) e gráfico das características operacionais do sistema, figura 7(l).

Figura 7: Fluxograma do método proposto para a classificação de frutos em estádios de maturação



Na primeira etapa foram adquiridos e utilizados 10 frutos de tomate, da variedade Santa Cruz Kada Gigante, no estágio de maturação verde maduro (figura 8a), verificado por meio de um Espectrofotômetro (Minolta CR-300, Lente de 8 mm).

Figura 8: Imagens adquiridas em laboratório. (a) Tomate verde maduro. (b) Tomate vermelho maduro.



Estes frutos foram levados para o laboratório, armazenados e fotografados sob uma plataforma giratória, em temperatura ambiente, a cada 24 horas, durante 10 dias, até o estágio de maturação vermelho maduro (figura 8b), verificado por meio do Espectrofotômetro. Este período temporal se refere à curva de amadurecimento do fruto, acréscimo de Licopeno e redução do índice de Clorofila (Radzevicius et al., 2014; Cantewll et al., 2010; Lana et al., 2005). Esta quantidade de frutos permite gerar um número mínimo de 250 imagens para a realização do experimento, seguindo a metodologia proposta por Roy et al., (2017), Bendary et al., (2015) e o Protocolo de Avaliação da Qualidade Química e Física (Moretti, 2006).

Para aquisição das imagens foi utilizada uma câmera Nikon (Modelo D3100, Sensor CMOS de 14.2 megapixels), capturando-se vídeos com 20 segundos de duração, em resolução de 640x424 *pixels* e taxa de 25 quadros por segundo. A partir destes vídeos, foram retiradas, automaticamente, por meio do software FFMPEG (Versão 20171208-4678339-win32-static), uma imagem para cada *frame* (quadro) de vídeo, em formato JPG, com resolução de 640x424 e espaço de cores RGB.

Para a aquisição de imagens em campo, uma câmera WanScam (Modelo HW0021-200W, Resolução 1080p, Sensor CMOS) foi instalada em uma casa de vegetação, situada na Faculdade de Engenharia Agrícola (FEAGRI), da Universidade

Estadual de Campinas (UNICAMP), em Campinas – SP (latitude 22° 49' 06" S, longitude 47° 03' 40" O, altitude de 635 metros acima do nível do mar), no período de julho de 2017 a setembro de 2017. Esta região possui classificação climática do tipo Cwa, caracterizada pelo clima tropical de altitude, com chuvas no verão e seca no inverno (Köppen, 2012).

A casa de vegetação possui área de piso de 117 m², dimensões de 6,4 m de largura, 18,3 m de comprimento, 4,0 m de pé direito, 1,5 m de altura do pé direito à cumeeira, coberta por filme de polietileno de baixa densidade (PEBD), difusor de luz com espessura de 150 µm e tratamento anti-ultravioleta, e sistemas de ventilação natural e mecânica, sombreamento e resfriamento evaporativo instalado e controle de ambiente (temperatura e umidade) instalado. O sistema de sombreamento é composto por uma tela termorefletora instalada horizontalmente na altura do pé direito.

As aquisições de imagens foram diárias, às 12 horas, apontado por Goel e Sehgal et al., (2015) como o horário em que as distorções nas cores dos frutos são mínimas. Foram produzidas imagens em formato JPG, resolução de 640x480, e espaço de cores RGB, conforme a figura 9a, com frutos no estágio verde, e figura 9b, com frutos no estágio vermelho.

Figura 9: Imagens da casa de vegetação. (a) Cor do estágio inicial. (b) Cor do estágio final.



(a)



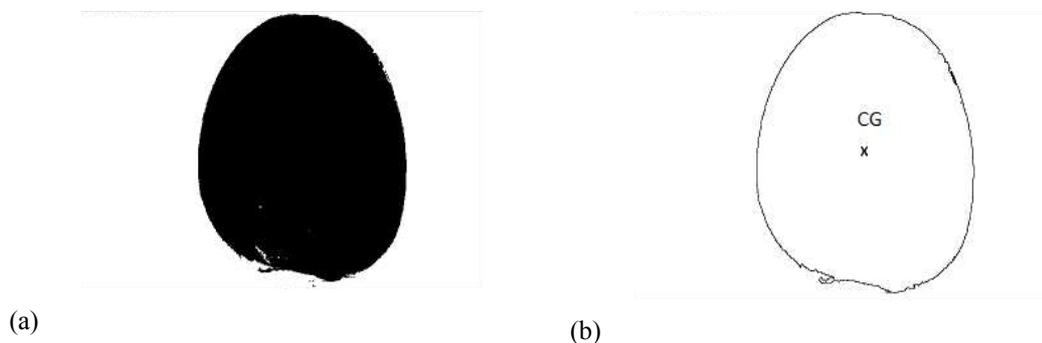
(b)

As imagens provenientes da casa de vegetação foram armazenadas localmente, em cartão de memória interno, além de enviadas por serviço de e-mail e para um servidor de arquivos em nuvem. Além disso, a câmera foi capaz de produzir vídeos, como forma de redundância aos serviços de armazenamento citados.

Na casa de vegetação, considerando uma maturação mais homogênea dos frutos, foram obtidas 250 imagens, a partir de 24 pés de tomate, durante toda a fase de acompanhamento do desenvolvimento dos frutos, a partir do verde maduro, até o estágio de cor vermelho maduro. Foram evitadas áreas de sombra e excesso de luminosidade. A quantidade de frutos na imagem ficou entre 1 e 5, como recomendada por Goel e Sehgal et al., (2015) para a aquisição de imagens. Nos cachos de frutos foram utilizados artefatos plásticos circulares, com diâmetro de 50 milímetros, nas cores vermelha, verde e azul, para ajustes e correções das cores nas imagens, seguindo o método proposto por Lu et al., (2016) e Zaborowicz et al., (2017).

Para a determinação da região de interesse (figura 10a) e do centro de gravidade (figura 10b) nas imagens em laboratório, utilizou-se o método proposto por Navnee et al., (2014) e Xiang et al., (2014), a qual segmenta os *pixels*, por meio da técnica OTSU. Neste processo a programação baseada em IMAGEJ (Versão 1.50i, Java 1.6.0_20, 32 bits) conseguiu separar o fruto do fundo presente nas imagens, independente do estágio de maturação.

Figura 10: Pós processamento das imagens. (a) Segmentação do fruto/fundo. (b) Determinação do centro de massa.



Para a identificação de frutos nas imagens da casa de vegetação e distinção para os demais objetos presentes, foram utilizadas as metodologias de segmentação de imagens propostas por Meyer et al., (2008), baseada em equações que acentuam ou

suprimem as cores verde e vermelha de um pixel na imagem. Como forma de detectar os frutos nos estádios intermediários de cor em ambiente protegido, utilizou-se também o método de Goel e Sehgal (2015), com isso, determinou-se as áreas de interesse para a obtenção das amostras dos frutos. Estas equações são apresentadas pela tabela 2 e foram avaliadas inicialmente com um padrão de cores conhecido, verificando-se as cores resultantes deste processo.

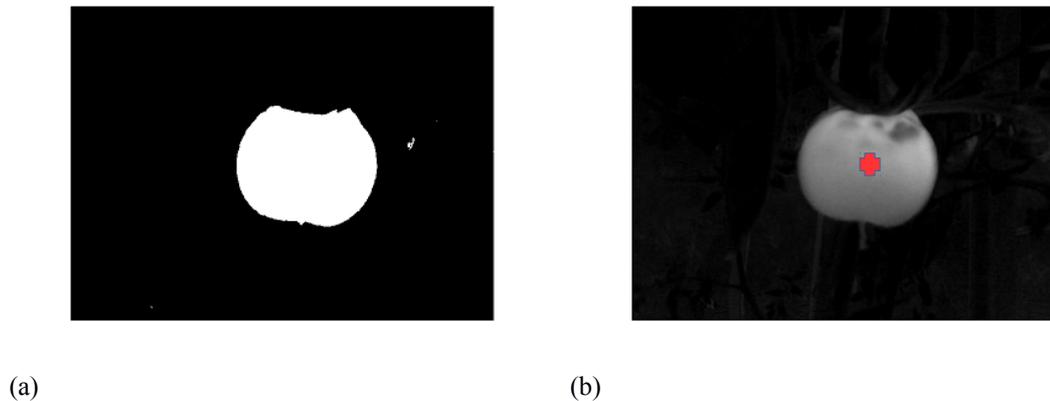
Tabela 2: Equações utilizadas na segmentação de imagens de Perissini (2008), originalmente estudadas por Meyer et al., (2008); Goel e Sehgal, (2015)

Equação	Resultado Esperado na Imagem (Destaque)
R-G	Cor vermelha e magenta
G-B	Cor amarela e verde
$(G-B)/(R-G)$	Cor amarela e verde
$ExG = 2.G-R-B$	Cor verde
$ExR = 1,4.R-B$	Cor vermelha e amarela
$(G-B)/(R+G)$	Cor verde e ciano
$(ExG)-(ExR)$	Cor verde
R/G	Cor verde, vermelha, amarela, magenta, branco

Todas as 250 imagens foram submetidas, de forma automatizada, a uma avaliação pelas equações apresentadas anteriormente, resultando na imagem de um fruto ou uma imagem em branco, caso nenhuma equação tenha conseguido detectá-lo. Ao final do processo, as imagens foram manualmente separadas para serem utilizadas na sequência do método, considerando somente aquelas com maior área de tomate detectada.

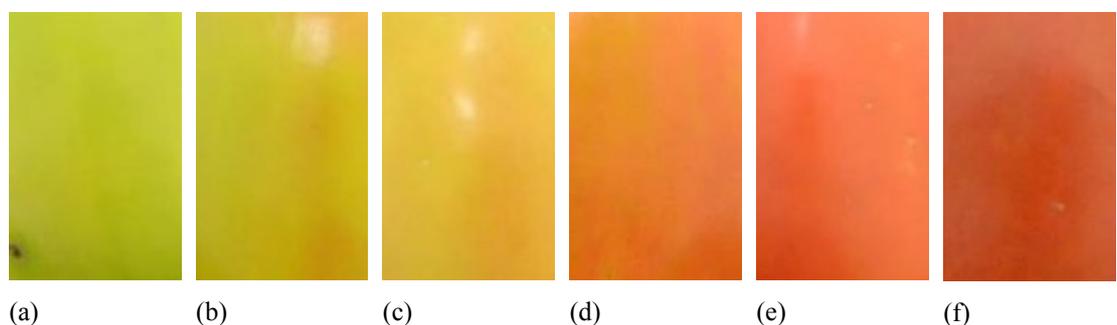
Neste processo de segmentação, a região de interesse (figura 11a) e o centro de massa (figura 11b) no fruto, foram obtidos a partir da imagem resultante em preto e branco.

Figura 11: Processo de segmentação das imagens adquiridas na casa de vegetação. (a) Segmentação de fruto e fundo. (b) Determinação do centro de massa no fruto e sua identificação.



A partir dos centros de massa, foram criadas imagens com resolução de 112×176 *pixels*, apresentadas pela figura 12. Atualmente existem outros métodos de obtenção de amostras de imagens em frutos, que são circulares no método de Wan et al., (2018) e convexos no método de Nyarko et al., (2018), neste trabalho adota-se o método estabelecido por Kirana et al., (2015), as amostras retangulares foram obtidas, dentro de um limite máximo de densidade de *pixels*, visando acelerar o processamento computacional. Na escolha das áreas nos frutos, foram evitados defeitos, reflexos de luz ou excesso de sombreamento, seguindo as orientações de Mollazade et al., (2012).

Figura 12: Amostras obtidas dos frutos em laboratório e separadas por cor entre verde até a cor vermelha



Para a avaliação, segundo Botelho (2010), a medida da cor de um alimento ocorre de uma forma subjectiva, por apreciação visual, ou objetiva, mediante o emprego de colorímetros ou até, em alguns casos, determinando-se quimicamente a

proporção das substâncias corantes. Desta forma, as imagens dos frutos adquiridas em laboratório e em casa de vegetação foram manualmente classificadas, em seis estádios de maturação, por 50 pessoas, baseando-se na avaliação de frutos de Ferreira et al., (2010). Utilizou-se um formulário digital na internet, apresentado pela figura 13, como método de cabine sensorial para a avaliação das cores (Ormenese et al., 2018; Sensenova, 2017).

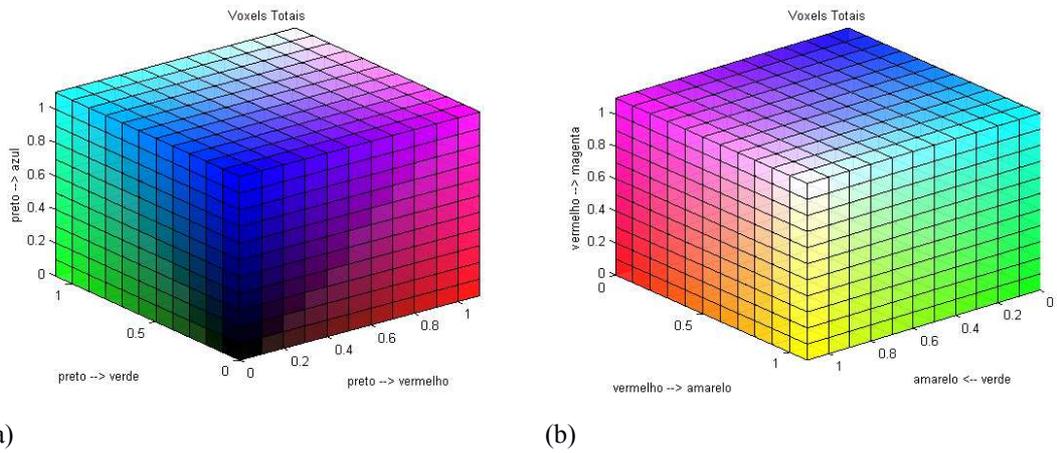
Figura 13: Formulário digital para a classificação manual das amostras de tomates

The image shows a digital form interface for manual classification of tomato samples. At the top, there are input fields for 'Nome:' and 'E-mail:', followed by an 'Enviar' button. Below this, the form is divided into three columns. Each column contains a small image of a tomato and a list of six radio buttons labeled 'Estadio 1' through 'Estadio 6'. The first column shows a green tomato, the second shows a yellowish-green tomato, and the third shows a yellow tomato. The radio buttons are arranged vertically next to each image.

Cada avaliador, com acesso à imagem da carta de classificação USDA, realizou a escolha no formulário do estágio semelhante ao recomendado pela norma. Estes dados foram armazenados em banco de dados relacional para posteriores consultas. Os valores obtidos nesta etapa são utilizados para a comparação com os valores obtidos pelo classificador automatizado. A ponderação dos resultados finais da classificação humana baseia-se na moda, onde são utilizados os valores mais frequentes, como indicada por Muniz (2017).

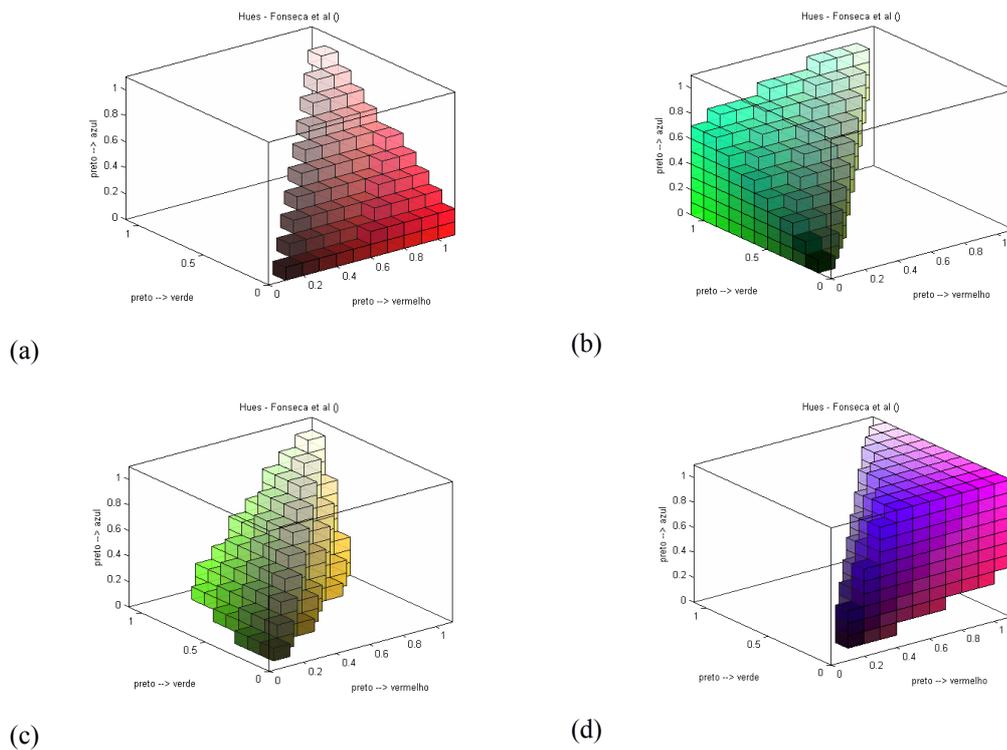
Conforme o espaço de representação de cores RGB das imagens adquiridas, foi construído digitalmente um volume tridimensional, apresentado na figura 14, utilizando uma escala de 11 níveis verticais e horizontais, totalizando 1331 cores. Em sua análise e segmentação de imagens, Byles et al., (2016), determinou que esta seria uma discretização adequada para a representação das cores, não utilizando todo o universo de 16 milhões de cores, com isso, diminuindo o esforço computacional para a classificação da cor dos *pixels*.

Figura 14: Cubo RGB. (a) Vista anterior destacando as cores verde, azul e vermelha. (b) Vista posterior destacando as cores vermelha, amarela e verde.



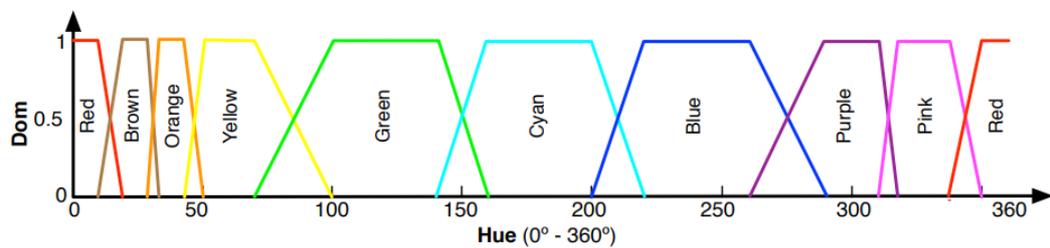
Para a classificação automatizada dos frutos, foi necessário o reconhecimento das quatro cores destacadas pela norma USDA: Vermelho, Verde, Amarelo e Magenta, as mesmas utilizadas na classificação de frutos proposta em Bharambe, et al., (2016). Estas cores alvo, foram agrupadas em sub-volumes tridimensionais (figura 15).

Figura 15: Volumes de cores. (a) Vermelho. (b) Verde. (c) Amarelo. (d) Magenta.



Os valores destes volumes foram criados a partir da conversão dos valores RGB para o espaço HSV, utilizado na classificação de frutos de Bendary et al., (2015), apontado como meio de agrupamento das cores em tonalidades, de acordo com a percepção humana. As escalas de valores utilizada foi baseada nos valores demonstrados por Fonseca et al., (2008), presentes na figura 16. Nestes volumes, foram utilizados os valores de HUE (Tonalidade): Vermelho (0° a 25° e 350° a 360°), Amarelo (45° a 100°), Verde (75° a 160°) e Magenta (260° a 340°).

Figura 16: Escala HUE proposta por Fonseca et al., (2008)



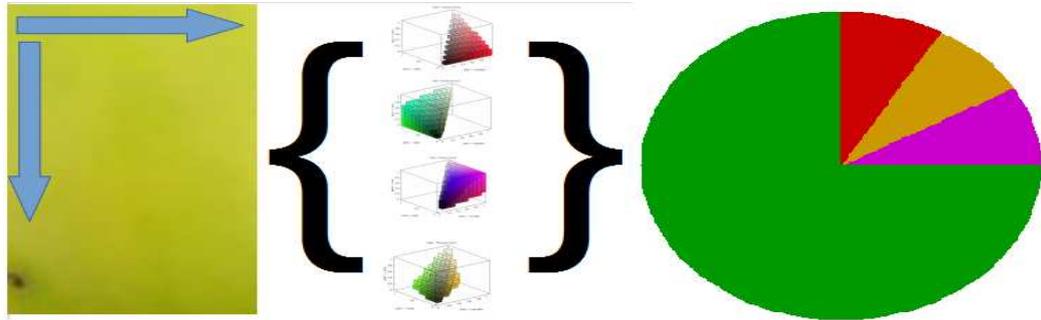
A partir dos volumes de cores, as imagens foram analisadas pixel a pixel, conforme o método proposto por Devalatkar et al., (2016), para a determinação de sua cor e área de cobertura, apresentado pelas figuras 17a e 17b. Esta indexação de cores é denominada por Lin et al., (2014), como *Color Book* ou ainda como *Lookup Table*. Na figura 18a observa-se a predominância da cor verde na área da amostra, já na figura 18b, denota-se a distribuição das cores vermelha e verde na amostra. Em ambos os casos, foram encontradas áreas não classificadas.

Figura 17: Análise dos *pixels* com a identificação da cor alvo e sua área útil de cobertura. (a) Tomates na cor verde maduro com 99,7% de área. (b) Tomates na cor vermelho maduro com 99,7% de área.



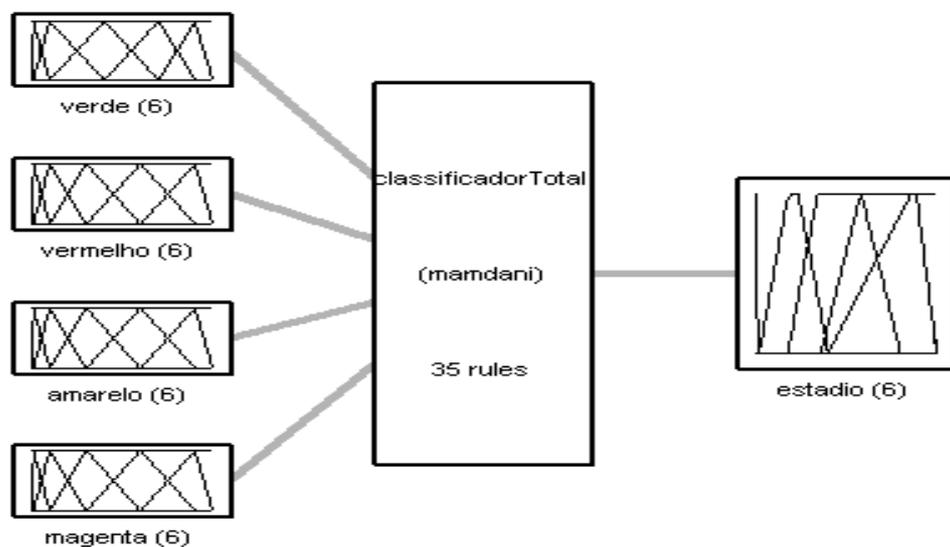
Nesta etapa, em cada amostra, o algoritmo determina as dimensões da imagem e sua área total, em seguida percorre os *pixels* horizontais e verticais, armazenando os valores em matrizes auxiliares que contém as somas numéricas parciais, apresentada pela figura 18. As áreas das cores encontradas são estabelecidas pela razão da área útil de *pixels* na imagem, bem como, pela área parcial daqueles que pertencem ao conjunto de cores alvo. Estas análises dos valores dos *pixels* foram apresentadas em Devalatkar et al., (2016), o qual determinam o estágio de maturação entre verde ou vermelho de um fruto. Se utilizado este método de classificação, para as quatro cores USDA e seis estágios de maturação, o algoritmo de decisão necessitaria de 1296 comparações para classificar os frutos. As áreas consideradas não classificadas são compostas por superfícies na cor branca, devido ao reflexo de luz ou *flash* da câmera, bem como, gotas de água ou defensivos agrícolas. Outras cores, como marrom, laranja, preta, representam defeitos, doenças ou déficit de nutrientes do tomateiro, conforme apresentado pelos estudos de Silva et al., (2006).

Figura 18: Análise dos pixels da imagem e composição das matrizes de área e cor



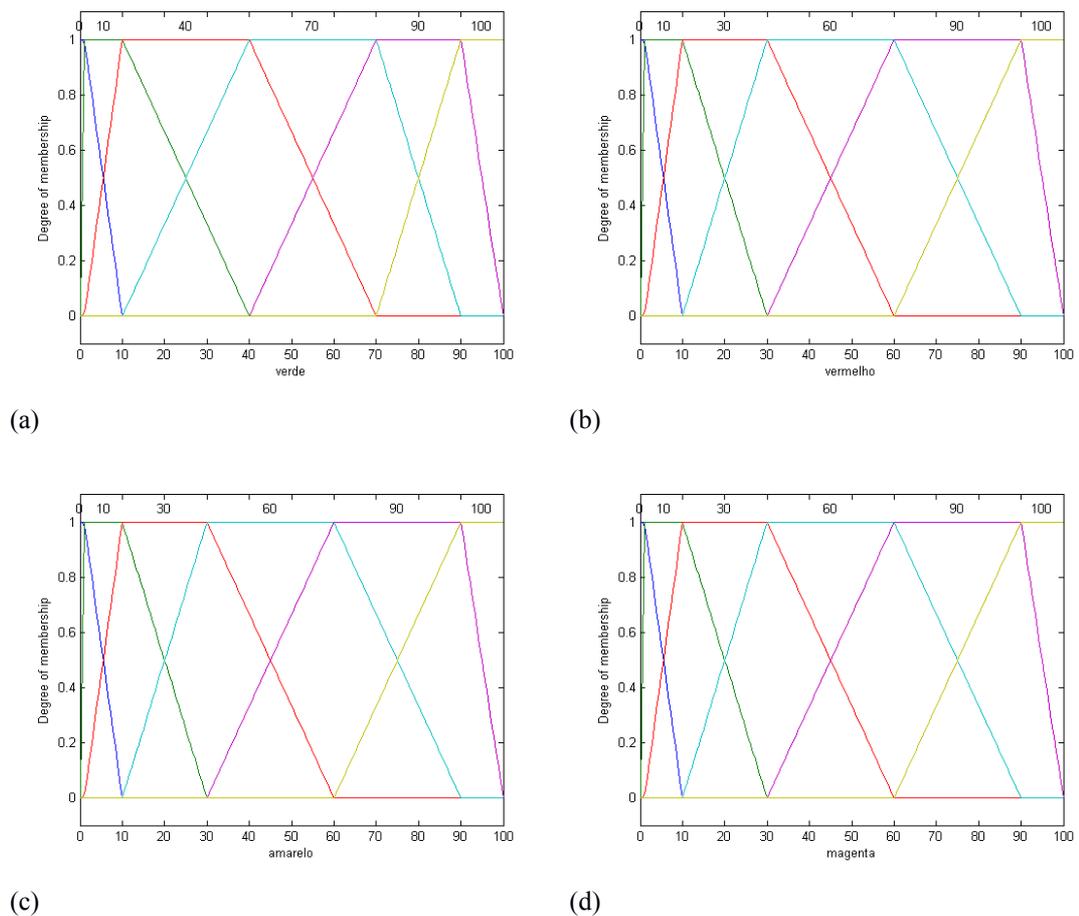
Para a classificação dos frutos em 6 estádios de maturação, de acordo com as áreas: 0, 10, 30, 60, 90 e 100%, estabelecidas pela USDA, foi criado um classificador baseado na lógica nebulosa, por meio do software MATLAB (Versão: 8.3.0.532 (R2014a), Sistema Operacional: Microsoft Windows 7 Starter – Versão 6.1 (Build 7601: Service Pack 1), Java Versão: 1.7.0_11-b21), utilizando o assistente gráfico *FUZZY*, o qual transforma as configurações em linhas de código. Este classificador utiliza o algoritmo de Mamdani, o mesmo utilizado por Mansor et al., (2015) na classificação de mangas. Contém quatro entradas com funções de pertinências trapezoidais adotadas por Mansor et al., (2015), apresentados pela figura 19.

Figura 19: Arquitetura do classificador por Lógica Fuzzy.



As entradas do classificador foram nomeadas como: verde (figura 20a), vermelho (figura 20b), amarelo (figura 20c) e magenta (figura 20d). Seus valores de pertinência foram divididos em uma escala de 0 a 100, em seis condições de análises possíveis.

Figura 20: Entradas do classificador por Lógica Fuzzy. (a) Verde. (b) Vermelha. (c) Amarela. (d) Magenta.



A partir das descrições de cores e áreas estabelecidas pela USDA, tabela 4, foram criadas 35 regras de defuzzificação, do tipo *centroid* (centro de massa) e as respostas do classificador foram avaliadas, a partir da inserção de dados numéricos conhecidos de áreas, conforme o teste de mesa proposto por Leite (2006); Rita (2009); Simões et al., (2001) para a avaliação do estágio de maturação em laranjas. Os valores utilizados foram: 10, 30, 60, 90 e 100, para a cor vermelha, adotados por Choi et al.,

(1995) na classificação de frutos baseada em colorímetro. As demais cores são ocorrências que podem ser apresentadas pelo fruto, segundo a USDA.

Tabela 4: Índices de cores e regras de defuzzificação propostas para o sistema de classificação de frutos

Estádio/Cor	Verde (%)	Vermelho (%)	Amarelo (%)	Magenta (%)
1	100	-	-	-
2	90	10	10	10
3	70	30	30	30
4	40	60	60	60
5	10	90	-	90
6	-	100	-	-

Após ajustes nas regras e valores das funções de pertinências, os dados numéricos das cores e respectivas áreas foram submetidos ao classificador de estádios. Os valores gerados foram armazenados em uma matriz NxM, onde N representa o número de entradas e M o número de amostras analisadas.

Dadas as características de respostas de um sistema multiclasse, as quais podem assumir valores entre 1 e 6, conforme o estágio de maturação encontrado e àquele definido pelo especialista, os resultados são, nesta etapa, condicionados, passando por arredondamento, para a análise pelo método de matrizes de confusão presente nos estudos de Thomas et al., (2012) e das características operacionais do sistema utilizado por Bendary et al., (2015) na classificação de frutos e mitigação de classificações inexatas.

Nesta etapa os dados obtidos são reorganizados, de maneira que sejam convertidos em índices lineares, levando em consideração as dimensões da matriz, das linhas e das colunas. Ao final deste processo, os valores multiclasse são convertidos em 0 e 1, de acordo com o resultado negativo ou positivo obtido na classificação. Os valores computados são comparados com aqueles esperados, denominados *TARGETS* ou *TRUE CLASSES*. Para uma melhor representação da exatidão do sistema, os dados presentes na matriz de confusão são submetidos a uma reclassificação para serem

visualizados dentro de um índice de cores, método utilizado por Liu et al., (2014), para a interpretação de modelos baseados em regressão de dados aleatórias, por O'Reilly et al., (2017) para a avaliação da tecnologia de múltiplos sensores acoplados à vestimenta.

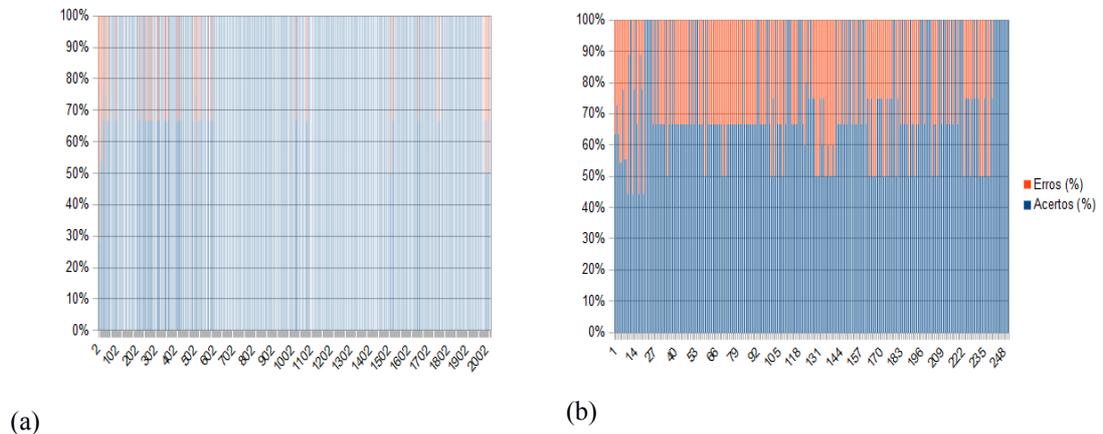
Para verificar a exatidão do sistema com os valores encontrados nas literaturas pesquisadas, realizou-se o levantamento dos índices gerais de acertos dos diversos métodos estudados por Goel e Sehgal (2015) e Bendary et al., (2015). Nestes trabalhos apresentam-se comparações entres sistemas de classificação, em ambos os casos, concluem que seus métodos possuem melhor exatidão do que os demais métodos utilizados.

Utilizando todas as imagens para avaliação pelo método proposto, verificando possíveis discrepâncias entre os dados avaliados e suas influências nos resultados, foram verificados os valores das cores apresentados por Goel e Sehgal (2015), referente às médias RGB, R-G e R/G, dos estádios 1 e 6, comparando-os com os valores referentes às imagens do presente estudo.

6. RESULTADOS E DISCUSSÕES

Na classificação manual dos tomates em laboratório (figura 21a) foram obtidas respostas mais homogêneas e na casa de vegetação (figura 21b), foram obtidas respostas heterogêneas, de forma que aproximadamente 50% dos avaliadores tiveram repostas divergentes daquelas utilizadas na obtenção da moda, referência para a comparação com o classificador fuzzy de estádios.

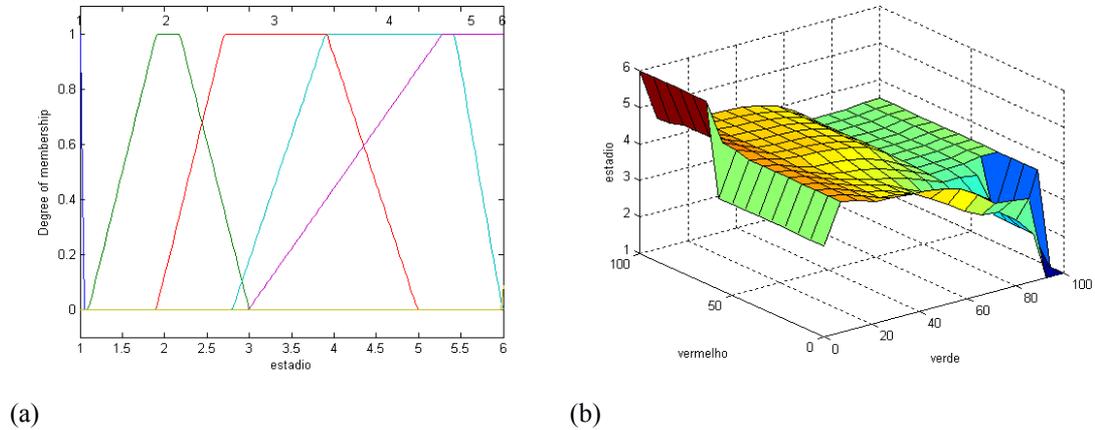
Figura 21: Resultado geral da classificação manual dos tomates. (a) 2015 imagens obtidas em laboratório. (b) 250 imagens obtidas na casa de vegetação.



O resultado demonstra a falta de consenso entre os participantes de qual seria o estágio de maturação, nas imagens dos tomates da casa de vegetação, apresentadas para a avaliação, mesmo assim, a partir das repostas válidas, foi possível obter um valor de estágio para cada imagem, como grau de concordância parcial para a utilização no classificador.

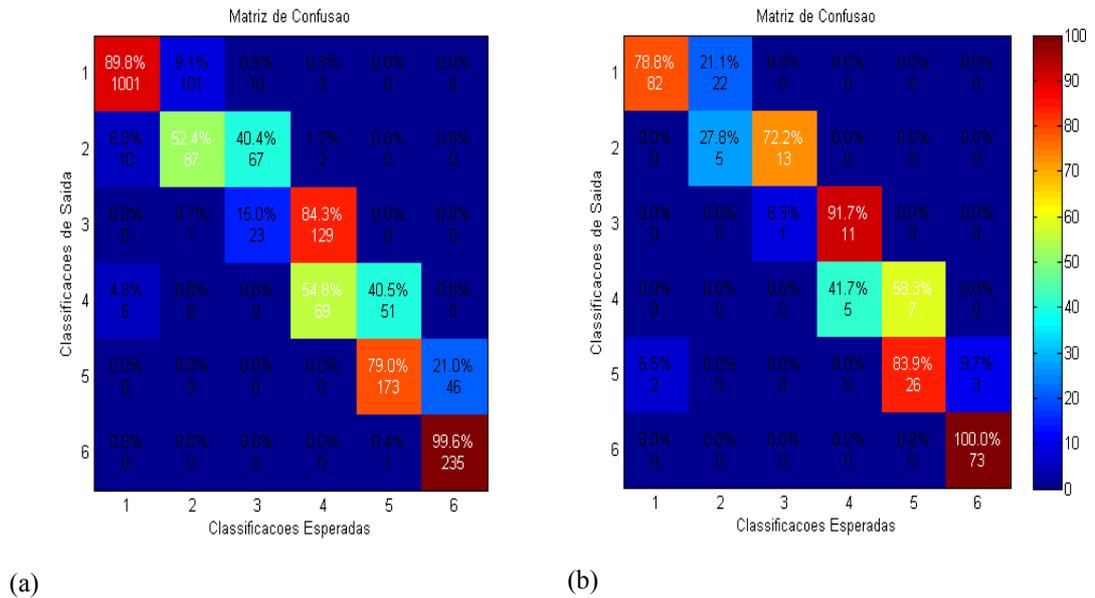
Para as seis respostas de saída esperada pelo sistema, foram utilizadas seis funções de pertinência, com valores de 1 a 6, conforme a figura 22a, a distribuição destas respostas segue esta mesma escala. A superfície de resposta do classificador *fuzzy* é apresentada pela figura 22b, destacando-se a interação entre as regras para a cor vermelha e verde.

Figura 22: Classificador por Lógica Fuzzy. (a) Regras de pertinência na saída de estádios. (b) Superfície de Resposta.



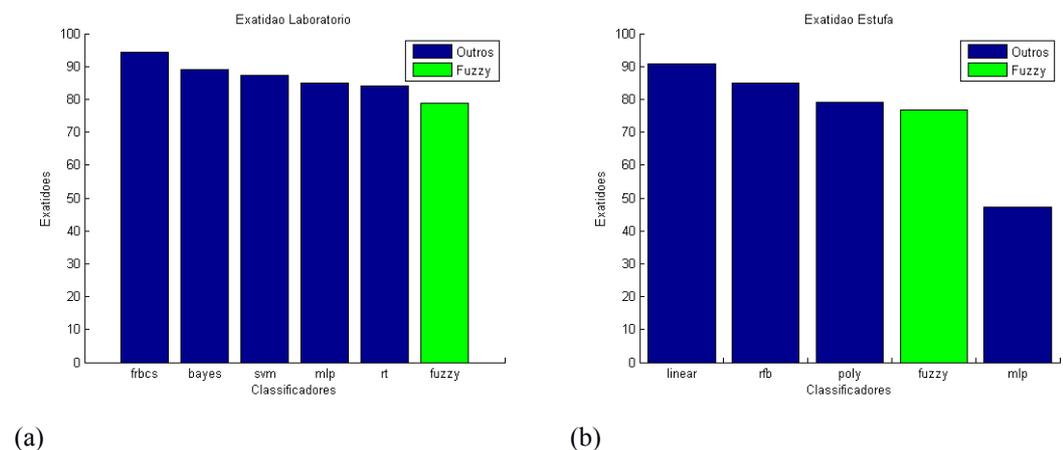
Os dados obtidos em laboratório e casa de vegetação foram condicionados para a análise pelo método de matriz de confusão, que para sua melhor representação dos valores de exatidão, foi submetida a uma reclassificação para ser visualizada em um índice de cores, conforme proposta apresentada por Fuentes et al., (2017), em sua análise de pragas no tomateiro. Os resultados obtidos em laboratório são apresentados pela figura 23a, onde a exatidão geral do sistema ficou em **78,8%** e o *recall* em **21,2%**. Os resultados obtidos na casa de vegetação são apresentados pela figura 23b, onde a exatidão geral do sistema ficou em **76,8%** e o *recall* **23,2%**. Ao procurar ajustar o sistema para melhorias nas respostas das amostras em laboratório, as exatidões se distanciam muito daquelas obtidas na casa de vegetação, devido à diferença nos números de imagens em cada caso e a variabilidade das respostas dos classificadores humanos, desta forma, optou-se por um sistema equilibrado para ambos ambientes de avaliação da maturação.

Figure 23: Matriz de confusão em mapa de cores. (a) Resultados laboratório. (b) Resultados estufa.



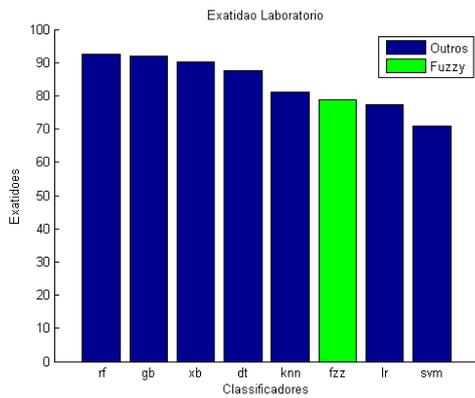
Quando comparadas as exatidões obtidas com a literatura, estas se aproximam daquela obtida por Goel e Sehgal et al., (2015) de **84%**, quando utilizadas as metodologias RT e MLP, conforme apresentado pela figura 24a. Estas exatidões obtidas superam aquela obtida por Bendary et al., (2015) de **47.20%**, quando utilizada a metodologia MLP, conforme a figura 24b, aproximando-se da metodologia Polynomial destes autores.

Figura 24: Comparação do resultado obtido. (a) Avaliações Goel e Sehgal (2015) e resultado da metodologia proposta em laboratório. (b) Avaliações Bendary et al., (2015) e resultado da metodologia proposta em casa de vegetação.

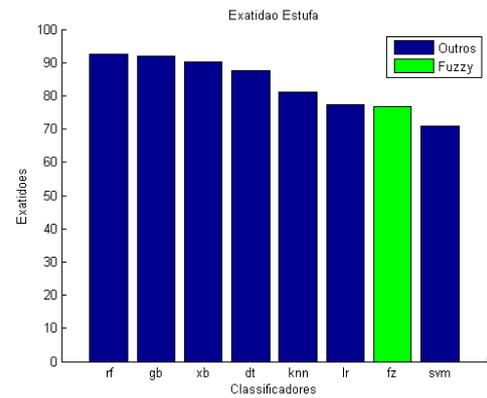


Quando comparados ambos resultados obtidos com a metodologia mais recente proposta por Gupta e Kaur, (2017), as exatidões obtidas no presente estudo superam aquelas obtidas em classificadores SVM, conforme apresentado pela figura 25a, para análise em laboratório e figura 25b, para análise em casa de vegetação.

Figura 25: Comparação do resultado obtido. (a) Dados do Laboratório. (b) Dados da Casa de vegetação.



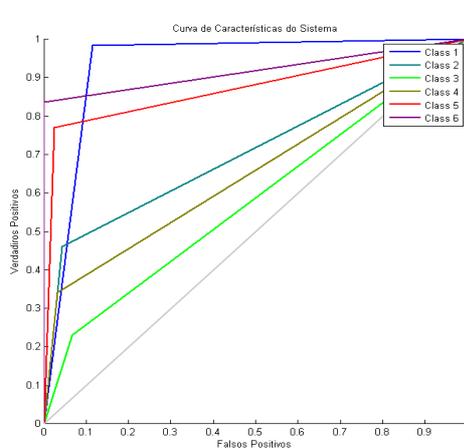
(a)



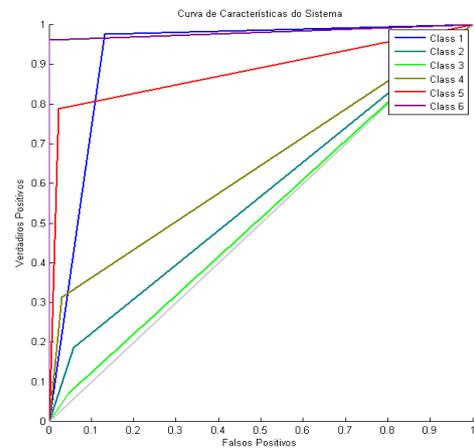
(b)

Para uma melhor representação do comportamento do sistema, verificando-se a relação da resposta verdadeiro positiva e falso positiva, utilizou-se as características operacionais (ROC), para as imagens em laboratório, conforme a imagem 26a e para casa de vegetação, conforme a figura 26b.

Figura 26: Curvas Operacionais do Sistema. (a) Resultados laboratório. (b) Resultados estufa.



(a)



(b)

Classificadores considerados mais eficientes, apresentam linhas do canto inferior esquerdo até o canto superior esquerdo e superior direito. Quando comparadas as curvas ROC com a metodologia de Bendary et al., (2015), as respostas obtidas são mais lineares e menos fragmentadas em cada classe. Além disso, os autores apresentam a curva ROC de forma invertida nos eixos X e Y, o que caracteriza um sistema propenso a falsos positivos e menos eficiente, mesmo com exatidões de 90,80%.

De maneira geral, os demais trabalhos, realizam a estimativa da maturação em fundos artificiais e ambiente controlados de laboratórios, estas técnicas tornam-se inexatas quando aplicadas na etapa pré colheita, em ambientes abertos, como em casas de vegetação. A abordagem proposta classifica os frutos por meio da lógica *fuzzy*, detectando os seis estádios de maturação dos tomates, não interferindo no seu crescimento em condições naturais, mantendo-se a integridade da cor, minimizando perdas de informação.

Os índices R-G e R/G são atributos eficientes no processo de segmentação, porém não são eficientes na descrição dos estádios de maturação de frutos de forma geral. A cada conjunto de dados, o sistema deverá recalcular os valores para poder estimar a maturação. Desta forma, quando utilizada a metodologia de Goel e Sehgal (2015) com o atual conjunto de imagens, as exatidões obtidas são de **36%** em laboratório e **14%** na casa de vegetação, conforme apresentado na figura 2 do Apêndice I. Supõe-se que esta influência esteja relacionada à espécie de tomate utilizada, bem como, com a área de amostra utilizada pelos autores, além de um número de imagens, aproximadamente, três vezes inferior ao recomendado por Bendary et al., (2015).

A exatidão (>90%) encontrada na literatura deve-se ao *overfitting* dos valores, nas metodologias propostas, de acordo com o conjunto de dados de cada pesquisa. Desta forma, os sistemas têm sido desenvolvidos para solucionar problemas específicos e não generalizados. Um novo conjunto de dados provoca considerável queda na exatidão geral e perda de eficiência. Em suma, as metodologias têm se apresentado eficientes em classificar os próprios frutos, não tratando o problema da classificação de forma abrangente. Bendary et al., (2015) busca eliminar este problema

ao treinar sua rede neural, separando grupos de dados menores e realizando avaliações cruzadas, desta forma foi precedido no presente trabalho.

Diferente de outras metodologias este trabalho não realiza o ajuste do classificador analisando o conjunto de dados, sendo eles, histograma, valores médios, valores mínimos e máximos das cores dos frutos. Trata o problema de forma generalizada, considerando objetivo de classificação as cores e áreas propostas pela USDA e não os próprios frutos utilizados na experimentação.

No padrão utilizado na comparação dos dados, utilizou-se como classificador especialista o ser humano, para avaliação da exatidão do classificador artificial, ao contrário da classificação utilizando outros frutos e métodos computacionais, que permitiriam exatidões aparentemente maiores. Ajustes nos valores máximos e mínimos das funções de pertinência do classificador *fuzzy*, permitiram melhorias nas exatidões obtidas, demonstrando que um aprimoramento destas funções deve ser realizado. Outra verificação deve ser realizada nas notas da classificação humana, para que contenham menos variações nas respostas.

Quanto as classes que geram maiores índices de incerteza, estas poderão ser agrupadas em uma única classe, de forma a atender as classificações nacionais de frutos, uma vez que fornecem uma baixa decisão na cadeia produtiva.

A diferenciação entre um sistema para avaliação de frutos em laboratório e casa de vegetação está principalmente ligada aos filtros aplicados no processo de segmentação. No primeiro caso, técnicas como OTSU foram eficientes, já no segundo caso, apenas as equações de Goel e Sehgal (2015), a mesma de Arefi et al., (2015), tiveram resultados na identificação dos frutos, pois relacionam-se diretamente com as cores USDA. Técnicas de detecção de bordas e outras metodologias propostas por Solomon e Breckon (2013) não foram eficientes.

Este trabalho, ao contrário de outras metodologias não redimensiona as imagens, mantendo todas as suas características originais, mesmo assim, foi capaz de detectar a maioria dos frutos sem um esforço computacional elevado. Embora trabalhos recentes proponham a aquisição das imagens em três dimensões, a análise aqui apresentada, oferece uma análise tridimensional das cores, levando em consideração a dispersão da luz sobre os frutos.

Durante as avaliações da projeção do espaço de cor RGB em memória, utilizando-se uma resolução de 1 pixel, o sistema não apresentou problemas quando o limite de *voxels* esteve abaixo de 262144 cores, consumido cerca de 1 minuto para a tarefa computacional e cerca de 10 *kbytes* de espaço em disco. Trabalhando-se com as técnicas de programação fuzzy e de segmentação de imagens, por meio das matrizes de dados, ao contrário de pontos isolados de *pixels* nas imagens, obteve-se uma otimização de performance eficiente, diminuindo-se desta forma o tempo de avaliação de cada imagem e do processo como um todo.

Em trabalhos futuros, a característica da câmera de aquisição de imagens em infravermelho deverá ser melhor explorada, visando uma segmentação adequada nas imagens obtidas, por meio de uma câmara de luz ou fotos noturnas, na casa de vegetação, como forma de auxiliar a segmentação.

Dada a diferença de resultados obtidos em laboratório e casa de vegetação, o número de imagens adquiridas também deverá ser levado em consideração, uma mesma câmera deverá ser utilizada em ambos ambientes, bem como, na forma em que o painel sensorial de avaliação exibirá as fotos para os classificadores humanos.

Para o aumento da performance computacional, poderão ser utilizadas técnicas de processamento de dados em *GPU* ou em rede de computadores (*cloud computing*), bem como utilizar técnicas de renderização de imagens por meio de nuvens de pontos ou isosuperfícies para a análise dos frutos. No classificador fuzzy poderão ser criadas classes adicionais de frutos não classificados, implementando-se a composição de funções de pertinências trapezoidal e triangular simultaneamente. Poderão ser adotados *voxels* na escala *hue*, sem conversão a partir do RGB ou deverá ser considerado o plano cônico tridimensional, ao invés do cubo tridimensional, para a comparação dos valores de cores, que automaticamente desconsidera o brilho presente nas imagens.

7. CONCLUSÕES

A hipótese do trabalho foi satisfeita, determinou-se o estágio de maturação de tomates em um ambiente protegido (casas de vegetação), utilizando técnicas de processamento de imagens e lógica fuzzy, que classifica a cor de tomates, por meio de padrões pré-determinados e a reproduzindo a capacidade de decisão humana em cerca de 80%, sendo todos os objetivos satisfeitos.

Mesmo não apresentando dados de exatidão total elevado, maior que 90%, a metodologia propõe um sistema mais sensível, em detrimento de um sistema mais específico, que tende a não identificar respostas incorretas ou que não possa ser adaptado para a análise de outras culturas agrícolas. Relacionando-se com a literatura, este trabalho poderá oferecer um auxílio para o momento da colheita, na análise da vida útil dos frutos, bem como, favorecer a tomada de decisão no campo, escolha dos mercados para a comercialização, por meios de técnicas de inteligência artificial.

8. REFERÊNCIAS BIBLIOGRÁFICAS

Arefi, Arman; Modarres Motlagh, Asad; Mollazade, Kaveh; Farrokhi Teimourlou, Rahman. Recognition and localization of ripen tomato based on machine vision. Australian Journal of Crop Science. 5. 2011

Carla M. Stinco; Francisco J. Rodríguez-Pulido; María Luisa Escudero-Gilete; Belén Gordillo; Isabel M. Vicario; Antonio J. Meléndez-Martínez. Lycopene isomers in fresh and processed tomato products: Correlations with instrumental color measurements by digital image analysis and spectroradiometry, Food Research International, Volume 50, Issue 1, 2013, Pages 111-120, ISSN 0963-9969

Cheng-Chang Lien; Chyung Ay; Ching-Hua Ting. Non-destructive impact test for assessment of tomato maturity, In Journal of Food Engineering, Volume 91, Issue 3, 2009, Pages 402-407, ISSN 0260-8774

Chuanyuan Zhao; Won Suk Lee; Dongjian He. Immature green citrus detection based on colour feature and sum of absolute transformed difference (SATD) using colour images in the citrus grove, Computers and Electronics in Agriculture, Volume 124, June 2016, Pages 243-253, ISSN 0168-1699

Cunha, Denise; S Dias, F; Pereira Ribeiro, Frederico; Antônio, Luiz & Dias, S; Silva, Derly; De, Deborah; Vidigal, Deborah. Maturação de sementes de tomate em função da ordem de frutificação na planta. 2018

D. Mylonas and L. MacDonald, 5 - Colour naming for colour design, In Woodhead Publishing Series in Textiles, edited by Janet Best, Woodhead Publishing, 2017, Pages 131-155, Colour Design (Second Edition), ISBN 9780081012703

Denis Claudio – Metodologia de Seleção de Tomates para Processamento Industrial por Meio da Visão Computacional e Redes Neurais.

<<http://maua.br/files/dissertacoes/metodologia-de-selecao-de-tomates-para-processamento-industrial.pdf>>. Acesso em: Setembro de 2017

E. Ceh-Varela; G. Hernandez-Chan. Tomatoes Classifier using Color Histograms. International Conference on Advances in Engineering Science and Management, Agra, 08 th November, 2015. ISBN: 978-81-931974-0-0

Elings, A.; Broekhuijsen, A.G.M.; Dieleman, J.A. The Relation between Physiological Maturity and Colour of Tomato Fruits. Proc. Int'l. WS on Models Plant Growth & Contr. Prod. Qual. in Hort. Prod. Eds. M. Fink and C. Feller. Acta Hort. 654, ISHS 2004

E.L. van den Broek; Th.E. Schouten; P.M.F. Kisters. Modeling human color categorization, In Pattern Recognition Letters, Volume 29, Issue 8, 2008, Pages 1136-1144, ISSN 0167-8655

Esmael Hamuda; Brian Mc Ginley; Martin Glavin; Edward Jones. Automatic crop detection under field conditions using the HSV colour space and morphological operations, Computers and Electronics in Agriculture, Volume 133, February 2017, Pages 97-107, ISSN 0168-1699

F. García-Luna; A. Morales-Díaz. Towards an artificial vision-robotic system for tomato identification, In IFAC-PapersOnLine, Volume 49, Issue 16, 2016, Pages 365-370, ISSN 2405-8963

Fernandes, Hugo Rafacho – Desenvolvimento, otimização e controle de um sistema de suspensão ativa para um veículo agrícola não tripulado. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/322513>>. Acesso em: Setembro de 2017

Fernando Mendoza; Petr Dejmek; José M. Aguilera. Calibrated color measurements of agricultural foods using image analysis, In *Postharvest Biology and Technology*, Volume 41, Issue 3, 2006, Pages 285-295, ISSN 0925-5214

Ferrari, Paulo Roberto – Avaliação da qualidade da classificação do tomate de mesa. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/257143>>. Acesso em: Setembro de 2017

Garcia, Angel Pontin – Sistemas de controle fuzzy para dosadores helicoidais de fertilizantes com acionamento elétrico. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/256880>>. Acesso em: Setembro de 2017

Gastélum Barrios, Abraham; A Bórquez-López, Rafael; Rico-García, Enrique; Toledano-Ayala, Manuel; M Soto-Zarazúa, Genaro. Tomato quality evaluation with image processing: A review. *African Journal of Agricultural Research*. 6. 2011

Hanli Zhao; Haining Zhang; Xiaogang Jin. Efficient image decolorization with a multimodal contrast-preserving measure, *Computers & Graphics*, 2017, ISSN 0097-8493

Hendrik N.J. Schifferstein; Bryan F. Howell; Sylvia C. Pont. Colored backgrounds affect the attractiveness of fresh produce, but not it's perceived color, *Food Quality and Preference*, Volume 56, 2017, Pages 173-180, ISSN 0950-3293

I. A. G. Boaventura; V. M. Volpe; I. N. da Silva and A. Gonzaga. "Fuzzy Classification of Human Skin Color in Color Images," 2006 IEEE International Conference on Systems, Man and Cybernetics, Taipei, 2006, pp. 5071-5075. doi: 10.1109/ICSMC.2006.385112

I. Kavdir; D.E. Guyer. Evaluation of different pattern recognition techniques for apple sorting, In *Biosystems Engineering*, Volume 99, Issue 2, 2008, Pages 211-219, ISSN 1537-5110

J. Senthilnath; Akanksha Dokania; Manasa Kandukuri; Ramesh K.N.; Gautham Anand, S.N. Omkar. Detection of tomatoes using spectral-spatial methods in remotely sensed RGB images captured by UAV, *Biosystems Engineering*, Volume 146, June 2016, Pages 16-32, ISSN 1537-5110

J. van Roy; J.C. Keresztes; N. Wouters; B. De Ketelaere; W. Saeys. Measuring colour of vine tomatoes using hyperspectral imaging, *Postharvest Biology and Technology*, Volume 129, 2017, Pages 79-89, ISSN 0925-5214

Jorge I. Aranda-Sanchez; Arturo Baltazar; Gustavo González-Aguilar. Implementation of a Bayesian classifier using repeated measurements for discrimination of tomato fruit ripening stages, *Biosystems Engineering*, Volume 102, Issue 3, March 2009, Pages 274-284, ISSN 1537-5110

Joshua Thomas; Matthew Lambert; Benjamin Snyder; Michael Janning; Jacob Haning; Yanglong Hu; Mohammad Ahmad; Sofia Visa. Learning Morphological Data of Tomato Fruits. Computer Science Department College of Wooster. Disponível em: <<http://ceur-ws.org/Vol-710/paper43.pdf>>. Acesso em: Novembro de 2017

Kassem, abd el-wahab s., M. A. Sabbah, a. M. Aboukarima and rabab m. Kamel. A study on color sorting of tomatoes maturity using machine vision and artificial neural networks. *Egypt. J. Agric. Res.*, 93 (1), 2015

Katrien Beullens; Péter Mészáros; Steven Vermeir; Dmitriy Kirsanov; Andrey Legin; Saskia Buysens; Nathalie Cap; Bart M. Nicolai; Jeroen Lammertyn. Analysis of tomato taste using two types of electronic tongues, *Sensors and Actuators B: Chemical*, Volume 131, Issue 1, 14 April 2008, Pages 10-17, ISSN 0925-4005

Kaveh Mollazade; Mahmoud Omid; Fardin Akhlaghian Tab; Sayed Saeid Mohtasebi; Manuela Zude. Spatial Mapping of Moisture Content in Tomato Fruits using Hyperspectral Imaging and Artificial Neural Networks. Disponível em: <<https://pdfs.semanticscholar.org/d5e3/58cd0a0a142ba1615572742ad6d7f772d5f6.pdf>>. Acesso em: Novembro de 2017

Kirana, Kartika Candra; Vandiar, Izzati; ainurrahman, Muhamad; Yulia Riska, Suastika.. Binary Adaptive Histogram Equalization Segmentation for Light Spot Detection in Tomato Maturity Classifications. 2015

L. Jarquín-Enríquez; E.M. Mercado-Silva; J.L. Maldonado; J. Lopez-Baltazar. Lycopene content and color index of tomatoes are affected by the greenhouse cover, *Scientia Horticulturae*, Volume 155, 2013, Pages 43-48, ISSN 0304-4238

Lopez Camelo, Andrés F.; Gomez, Perla A.. Comparison of color indexes for tomato ripening. *Hortic. Bras.*, Brasília , v. 22, n. 3, p. 534-537, Sept. 2004

Lagorio. Guide to Ripening Stages. Disponível em: <<http://www.lagorio.com/assets/pdf/lagorio-tomato-guide.pdf>>. Acesso em: Novembro de 2017

Lee H; Kim MS; Jeong D; Delwiche SR; Chao K; Cho B-K. Detection of Cracks on Tomatoes Using a Hyperspectral Near-Infrared Reflectance Imaging System. *Sensors* (Basel, Switzerland). 2014;14(10):18837-18850. doi:10.3390/s141018837.

Lenard C. Dorado; Jules Ian C. Aguila; Rionel B. Caldo. Smart Farm: Automated Classifying and Grading System of Tomatoes using Fuzzy Logic. *LPU-Laguna Journal of Engineering and Computer Studies*. Vol. 3 No.3 October 2016

Lu Zhang; Michael J. McCarthy. Measurement and evaluation of tomato maturity using magnetic resonance imaging, *Postharvest Biology and Technology*, Volume 67, May 2012, Pages 37-43, ISSN 0925-5214

M. F. Abu Hassan; Y. Yusof; M.A. Azmi; M.N. Mazli. Fuzzy Logic Based Intelligent Control of RGB Colour Classification System for Undergraduate Artificial Intelligence Laboratory. ISBN: 978-988-19252-1-3. ISSN: 2078-0958 (Print); ISSN: 2078-0966 (Online)

M.M. Lana; L.M.M. Tijskens; A. de Theije; M. Hogenkamp; O. van Kooten. Assessment of changes in optical properties of fresh-cut tomato using video image analysis, *Postharvest Biology and Technology*, Volume 41, Issue 3, September 2006, Pages 296-306, ISSN 0925-5214

Maciej Zaborowicz; Piotr Boniecki; Krzysztof Koszela; Andrzej Przybylak; Jacek Przyby. Application of neural image analysis in evaluating the quality of greenhouse tomatoes, *Scientia Horticulturae*, Volume 218, 2017, Pages 222-229, ISSN 0304-4238

Manasi G. Bharambe; Jigar J. Lodha; Pratiksha P. Kor. *International Journal of Advanced Research in Computer and Communication Engineering* Vol. 5, Issue 4, April 2016. ISSN (Online) 2278-1021. ISSN (Print) 2319 5940

Mansor, Razak; Mahmud, Othman; Ali, Noor; Ahmad, Khairul Adilah; Elias, Shamsul Jamel. CHAPTER 35 A Fuzzy Rule Base System For Mango Ripeness Classification. 369-380. 2015

Mohd, Alif Syami Bin Azmi; Nazrul, Bin Mazli; Yusof, Yusman; Mohd Fadzil, Abu Hassan. Study of RGB Color Classification Using Fuzzy Logic. Conference: Conference: Engineering Technology Empowerment via R&D, ETERD 2010, At Universiti Kuala Lumpur, Malaysia France Institute, Volume: 1, 2010

Nashwa El-Bendary; Esraa El Hariri; Aboul Ella Hassanien; Amr Badr. Using machine learning techniques for evaluating tomato ripeness, *In Expert Systems with Applications*, Volume 42, Issue 4, 2015, Pages 1892-1905, ISSN 0957-4174

Nidhi Goel; Priti Sehgal. Fuzzy classification of pre-harvest tomatoes for ripeness estimation – An approach based on automatic rule learning using decision tree, *Applied Soft Computing*, Volume 36, November 2015, Pages 45-56, ISSN 1568-4946

Olaia Liñero; Maite Cidad; Gorka Arana; Christophe Nguyen; Alberto de Diego. The use of a standard digital camera as an inexpensive, portable, fast and non-destructive analytical tool to measure colour: Estimation of the ripening stage of tomatoes () as a case study, *Microchemical Journal*, Volume 134, 2017, Pages 284-288, ISSN 0026-265X

P. Pabico, Jaderick; V. De Grano, Alona; L. Zarsuela, Alan. *Neural Network Classifiers for Natural Food Products*. 2015

Peng Wan; Arash Toudeshki; Hequn Tan; Reza Ehsani. A methodology for fresh tomato maturity detection using computer vision, *Computers and Electronics in Agriculture*, Volume 146, March 2018, Pages 43-50, ISSN 0168-1699

Prof. Pramod G. Devalatkar; Mrs. Shilpa R. Koli. Identification of Age Factor of Fruit (Tomato) using Matlab- Image Processing. *International Journal of Recent Trends in Engineering & Research (IJRTER)*. Volume 02, Issue 07; July - 2016 [ISSN: 2455-1457]

Radzevicius, Audrius; Viškelis, Jonas; Karkleliene, Rasa; Juškeviciene, Danguole; Viskelis, Pranas. Determination of tomato quality attributes using near infrared spectroscopy and reference analysis. *Zemdirbyste-Agriculture*. 103. 443-448. 10.13080/z-a.2016.103.012. 2016

Rich, E.; Knight, K. (1994). *Inteligência Artificial*. Makron Books do Brasil (Segunda edição).

Rong Xiang; Huanyu Jiang; Yibin Ying. Recognition of clustered tomatoes based on binocular stereo vision, In *Computers and Electronics in Agriculture*, Volume 106, 2014, Pages 75-90, ISSN 0168-1699

Rui Lu; Mingwei Shao. Sphere-based calibration method for trinocular vision sensor, *Optics and Lasers in Engineering*, Volume 90, 2017, Pages 119-127, ISSN 0143-8166

Schillaci G.; Pennisi A.; Franco F.; Longo D.. Detecting tomato crops in greenhouses using a vision based method. International Conference RAGUSA SHWA 2012, September 3-6, 2012, Ragusa – Italy. “Safety Health and Welfare in Agriculture and in Agro-food Systems”

Soares, Fabricio Theodoro - Controladores fuzzy aplicados em um sistema de geração de energia elétrica embarcado em tratores para o acionamento de implementos agrícolas. Disponível em:

<<http://repositorio.unicamp.br/jspui/handle/REPOSIP/256771>>. Acesso em: Setembro de 2017

Stefany Cárdenas-Pérez; Jorge Chanona-Pérez; Juan V. Méndez-Méndez; Georgina Calderón-Domínguez; Rubén López-Santiago; María J. Perea-Flores; Israel Arzate-Vázquez. Evaluation of the ripening stages of apple (Golden Delicious) by means of computer vision system, In *Biosystems Engineering*, Volume 159, 2017, Pages 46-58, ISSN 1537-5110

Subhajt Sengupta; Won Suk Lee. Identification and determination of the number of immature green citrus fruit in a canopy under different ambient light conditions, *Biosystems Engineering*, Volume 117, January 2014, Pages 51-61, ISSN 1537-5110

Wilson, Andrew; Ben-Tal, Gadi; Heather, Jamie; Oliver, Richard; Valkenburg, Robert. Calibrating cameras in an industrial produce inspection system, *Computers and Electronics in Agriculture*, Volume 140, 2017, Pages 386-396, ISSN 0168-1699

Yuan Ting; Naoshi Kondo; Li Wei. Sunlight Fluctuation Compensation for Tomato Flower Detection Using Web Camera, In *Procedia Engineering*, Volume 29, 2012, Pages 4343-4347, ISSN 1877-7058

Yuanshen Zhao; Liang Gong; Bin Zhou; Yixiang Huang. Chengliang Liu, Detecting tomatoes in greenhouse scenes by combining AdaBoost classifier and colour analysis, *Biosystems Engineering*, Volume 148, August 2016, Pages 127-137, ISSN 1537-5110

Yud-Ren Chen; Kuanglin Chao; Moon S Kim. Machine vision technology for agricultural applications, In *Computers and Electronics in Agriculture*, Volume 36, Issues 2–3, 2002, Pages 173-191, ISSN 0168-1699

Zhiguo Li; Kun Lv; Yuqing Wang; Bo Zhao; Zhibo Yang. Multi-scale engineering properties of tomato fruits related to harvesting, simulation and textural evaluation, *LWT - Food Science and Technology*, Volume 61, Issue 2, 2015, Pages 444-451, ISSN 0023-6438

Zoe Falomir; Lledó Museros; Luis Gonzalez-Abril. A model for colour naming and comparing based on conceptual neighbourhood. An application for comparing art compositions, In *Knowledge-Based Systems*, Volume 81, 2015, Pages 1-21, ISSN 0950-7051

APÊNDICE

Tabela 1: Comparação entre índices de cor dos frutos de Goel e Sehgal (2015) e dados atuais

Índice	Goel e Sehgal (2015)	Metodologia Proposta
Média Vermelho (1)	166,79	172,67
Média Verde (1)	162,23	196,79
Média Azul (1)	55,53	41,79
Média Vermelho (6)	230,83	223,62
Média Verde (6)	84,09	91,66
Média Azul (6)	33,80	49,11
R-G (1)	4,07	24,12
R-G (6)	146,73	131,96
R/G (1)	1,03	0,88
R/G (6)	2,80	2,44

Figura 1: Matrizes de confusão originais. (a) Dados Laboratório. (b) Dados Casa de vegetação.

Matriz de Confusão

1	1001 49.7%	101 5.0%	10 0.5%	3 0.1%	0 0.0%	0 0.0%	89.8% 10.2%
2	10 0.5%	87 4.3%	67 3.3%	2 0.1%	0 0.0%	0 0.0%	52.4% 47.6%
3	0 0.0%	1 0.0%	23 1.1%	129 6.4%	0 0.0%	0 0.0%	15.0% 85.0%
4	6 0.3%	0 0.0%	0 0.0%	69 3.4%	51 2.5%	0 0.0%	54.8% 45.2%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	173 8.6%	46 2.3%	79.0% 21.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	235 11.7%	99.6% 0.4%
	98.4% 1.6%	46.0% 54.0%	23.0% 77.0%	34.0% 66.0%	76.9% 23.1%	83.6% 16.4%	78.8% 21.2%
	1	2	3	4	5	6	
	Classificações Esperadas						

(a)

Matriz de Confusão

1	82 32.8%	22 8.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	78.8% 21.2%
2	0 0.0%	5 2.0%	13 5.2%	0 0.0%	0 0.0%	0 0.0%	27.8% 72.2%
3	0 0.0%	0 0.0%	1 0.4%	11 4.4%	0 0.0%	0 0.0%	8.3% 91.7%
4	0 0.0%	0 0.0%	0 0.0%	5 2.0%	7 2.8%	0 0.0%	41.7% 58.3%
5	2 0.8%	0 0.0%	0 0.0%	0 0.0%	26 10.4%	3 1.2%	83.9% 16.1%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	73 29.2%	100% 0.0%
	97.6% 2.4%	18.5% 81.5%	7.1% 92.9%	31.3% 68.8%	78.8% 21.2%	96.1% 3.9%	76.8% 23.2%
	1	2	3	4	5	6	
	Classificações Esperadas						

(b)

CLASSIFICAÇÃO DAS IMAGENS POR AVALIADORES HUMANOS

Tabela 2: Resultados das classificações manuais por avaliadores humanos com 90 amostras propostas por Goel e Sehgal, (2015).

Laboratório (90 imagens)		Casa de Vegetação (90 imagens)	
Classe 1	32	Classe 1	22
Classe 2	10	Classe 2	23
Classe 3	15	Classe 3	12
Classe 4	16	Classe 4	3
Classe 5	4	Classe 5	11
Classe 6	13	Classe 6	19

Tabela 3: Resultados das classificações manuais por avaliadores humanos com todas as amostras

Laboratório (2015 imagens)		Casa de Vegetação (250 imagens)	
Classe 1	1017	Classe 1	43
Classe 2	189	Classe 2	46
Classe 3	100	Classe 3	53
Classe 4	203	Classe 4	23
Classe 5	225	Classe 5	28
Classe 6	281	Classe 6	57

FRUTOS ENCONTRADOS NAS EQUAÇÕES UTILIZADAS – ESTUFA

Tabela 4: Resultados obtidos durante as segmentações das imagens em casa de vegetação, utilizando as equações de Perissini (2008), originalmente estudadas por Meyer et al., (2008); Goel e Sehgal, (2015).

Eq. 1	Eq. 2	Eq. 3	Eq. 4	Eq. 5	Eq. 6	Eq. 7	Eq. 8	Eq. 9	Eq. 10
48	48	39	41	25	1	35	38	13	2

AVALIAÇÕES SEGUNDO METODOLOGIA GOEL E SEHGAL (2015)

Figura 2: Resultados obtidos na utilização da metodologia proposta por Goel e Sehgal, (2015). (a) Exatidão de **35,9%** obtida em laboratório. (b) Exatidão de **13,6%** obtida em casa de vegetação.

Confusion Matrix

	1	2	3	4	5	6	
1	363 18.0%	18 0.9%	8 0.4%	0 0.0%	0 0.0%	0 0.0%	93.3% 6.7%
2	142 7.0%	43 2.1%	4 0.2%	4 0.2%	0 0.0%	0 0.0%	22.3% 77.7%
3	499 24.8%	76 3.8%	17 0.8%	2 0.1%	0 0.0%	0 0.0%	2.9% 97.1%
4	13 0.6%	51 2.5%	60 3.0%	114 5.7%	39 1.9%	40 2.0%	36.0% 64.0%
5	0 0.0%	1 0.0%	11 0.5%	83 4.1%	186 9.2%	241 12.0%	35.6% 64.4%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	35.7% 64.3%	22.8% 77.2%	17.0% 83.0%	56.2% 43.8%	82.7% 17.3%	0.0% 100%	35.9% 64.1%
	1	2	3	4	5	6	

(a)

Confusion Matrix

	1	2	3	4	5	6	
1	5 2.0%	20 8.0%	22 8.8%	6 2.4%	0 0.0%	0 0.0%	9.4% 90.6%
2	0 0.0%	1 0.4%	15 6.0%	8 3.2%	2 0.8%	0 0.0%	3.8% 96.2%
3	38 15.2%	25 10.0%	16 6.4%	6 2.4%	6 2.4%	18 7.2%	14.7% 85.3%
4	0 0.0%	0 0.0%	0 0.0%	1 0.4%	9 3.6%	13 5.2%	4.3% 95.7%
5	0 0.0%	0 0.0%	0 0.0%	2 0.8%	11 4.4%	26 10.4%	28.2% 71.8%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	11.6% 88.4%	2.2% 97.8%	30.2% 69.8%	4.3% 95.7%	39.3% 60.7%	0.0% 100%	13.6% 86.4%
	1	2	3	4	5	6	

(b)

AVALIAÇÕES SEGUNDO METODOLOGIA MANSOR ET AL., (2015)

Figura 3: Resultados obtidos na utilização da metodologia proposta por Mansor et al., (2015). (a) Exatidão de **5,0%** obtida em laboratório. (b) Exatidão de **20,8%** obtida em casa de vegetação.

Confusion Matrix

	1	2	3	4	5	6	
1	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
2	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
3	1014 50.3%	189 9.4%	100 5.0%	203 10.1%	225 11.2%	281 13.9%	5.0% 95.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
6	3 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	0.0% 100%	0.0% 100%	100% 0.0%	0.0% 100%	0.0% 100%	0.0% 100%	5.0% 95.0%
	1	2	3	4	5	6	

(a)

Confusion Matrix

	1	2	3	4	5	6	
1	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
2	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
3	40 16.0%	46 18.4%	52 20.8%	23 9.2%	28 11.2%	57 22.8%	21.1% 78.9%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
6	3 1.2%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	0.0% 100%	0.0% 100%	98.1% 1.9%	0.0% 100%	0.0% 100%	0.0% 100%	20.8% 79.2%
	1	2	3	4	5	6	

(b)

CLASSIFICADOR DE ESTÁDIOS DE MATURAÇÃO EMBARCADO

Figura 2: Interface gráfica sugerida para o sistema de classificação de estádios de maturação.

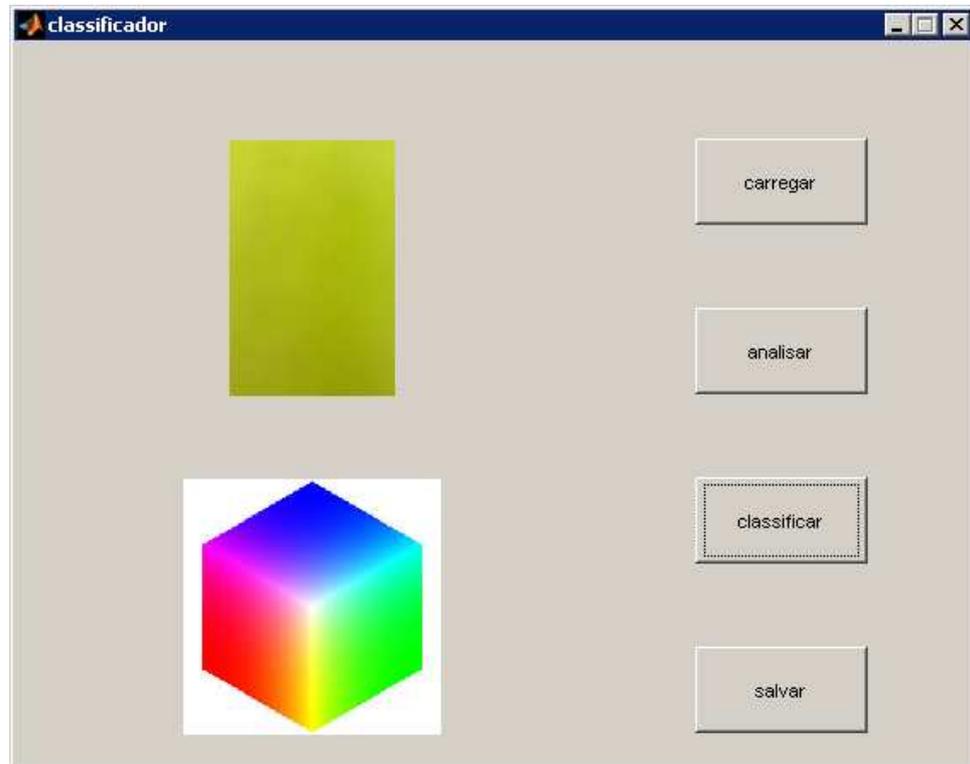


Figura 3: Programação em blocos do sistema embarcado de classificação de estádios de maturação.

