



UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE ENGENHARIA QUÍMICA E ENGENHARIA DE ALIMENTOS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ALIMENTOS

Wilson Daniel Caicedo Chacon

Estimativa do estágio de maturação, volume e massa do mamão (*Carica papaya* L.) por meio de processamento de imagens para classificação automatizada

Florianópolis

2022

Wilson Daniel Caicedo Chacon

Estimativa do estágio de maturação, volume e massa do mamão (*Carica papaya* L.) por meio de processamento de imagens para classificação automatizada

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Alimentos da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Engenharia de Alimentos.

Orientador: Prof. Dr. Germán Ayala Valencia.

Coorientador: Prof. Dr. Sergio Yesid Gómez González,
Prof. Dra. Alcilene Rodrigues Monteiro Fritz.

Florianópolis

2022

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Caicedo Chacon, Wilson Daniel

Estimativa do estágio de maturação, volume e massa do mamão (Carica papaya L.) por meio de processamento de imagens para classificação automatizada / Wilson Daniel Caicedo Chacon ; orientador, Germán Ayala Valencia, coorientadora, Alcilene Rodrigues Monteiro Fritz, coorientador, Sergio Yesid Gómez Gonzales, 2022.

80 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia de Alimentos, Florianópolis, 2022.

Inclui referências.

1. Engenharia de Alimentos. 2. Processamento de imagem. 3. Estimativa de parâmetros. 4. Frutas. 5. Pós-colheita. I. Ayala Valencia, Germán. II. Rodrigues Monteiro Fritz, Alcilene. III. Gómez Gonzales, Sergio Yesid IV. Universidade Federal de Santa Catarina. Programa de Pós Graduação em Engenharia de Alimentos. V. Título.

Wilson Daniel Caicedo Chacon

Estimativa do estágio de maturação, volume e massa do mamão (*Carica papaya* L.) por meio de processamento de imagens para classificação automatizada

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. André Wüst Zibetti, Dr.
Universidade Federal de Santa Catarina

Prof. Lenilton Santos Soares, Dr.
Universidade Federal de Lavras

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Engenharia de Alimentos.

Coordenação do Programa de Pós-Graduação

Prof. Germán Ayala Valencia, Dr.
Orientador

Florianópolis, 2022.

Dedico este trabalho às pessoas mais importantes da minha vida,
aos meus pais.

AGRADECIMENTOS

Agradeço à minha família porque sempre confiaram em mim e me motivaram a dar o exemplo a quem deseja progredir na vida acadêmica.

À minha mãe Nori Chacon Angulo e ao meu pai José Wilson Caicedo, que deram a vida inteira para que eu pudesse progredir pessoal e academicamente.

Ao meu irmão José Luis por sempre acreditar e ter fé em mim para alcançar meus objetivos.

À minha namorada Geraldine Caicedo, que é a pessoa que tem me permitido manter a estabilidade mental e emocional para superar todos os obstáculos acadêmicos que me foram apresentados.

À minha professora Ana Cecilia Agudelo Henao que me apaixonou pelo mundo da pesquisa e sempre acreditou em mim para continuar progredindo.

Ao meu orientador Germán Ayala Valencia, a quem muito admiro por sua grande capacidade de trabalho e sabedoria e por me motivar a continuar, um dia quero ser como ele.

Aos coorientadores Alcilene Monteiro e Sergio Yesid por orientar meu trabalho e me dar ideias para melhorá-lo.

A Jaízia Santos pela paciência e pelas medidas em laboratório, que me permitiram iniciar minhas pesquisas.

Ao grupo Nanobio & Food Research pelo apoio.

À CAPES pela bolsa de estudos.

À Universidade Federal de Santa Catarina, que tem professores de excelente qualidade com quem aprendi muito.

E agradeço a todos os outros que de alguma forma contribuíram para me ajudar a chegar onde estou agora.

Muito obrigado!

"A disciplina, mais cedo ou mais tarde,
derrotará a inteligência" (Yokoi Kenji)

RESUMO

A visão artificial por meio de metodologias computacionais pode ser utilizada para classificar as frutas com eficiência e segurança durante a pós-colheita. O Brasil é um dos principais produtores de mamão (*Carica papaya* L.), sendo que a classificação desta fruta durante a pós-colheita é feita principalmente por triagem manual. Este estudo teve como objetivo desenvolver uma metodologia computacional, não destrutiva por meio de análise de imagens para classificar o mamão (*Carica papaya* L.) com base no seu estado de maturação tendo em conta a cor da pele, volume e massa. Primeiramente, os mamões foram classificados visualmente de acordo com a cor da pele, o volume e a massa foram determinados experimentalmente. Na sequência, as imagens dos mamões foram adquiridas utilizando uma câmera digital para posterior processamento. Os mamões foram classificados de acordo com o estado de maturação, volume e massa, utilizando metodologias computacionais, nas quais inicialmente foi realizada a conversão do espaço de cor RGB para HSV e CIElab, a fim de identificar a fruta na imagem e fazer estimativas das diferentes parâmetros. Os resultados obtidos experimentalmente foram comparados com os obtidos computacionalmente. A predição do estágio de maturação teve uma estimativa global de 95% em relação aos dados experimentais. Paralelamente, o volume e a massa estimadas não diferiram estatisticamente dos valores experimentais, no entanto, a classificação baseada no tamanho (pequeno, médio e grande) apresentou uma melhor estimativa com os valores de volume estimados ($C (\%) = 90,5$) em relação à estimativa global da massa ($C (\%) = 77,9$) calculada a partir da densidade média ($\bar{\rho}$). E por fim, foi possível melhorar a estimativa do cálculo da massa através do uso de regressões lineares. Através da relação linear da densidade com a altura e volume estimado, foi possível melhorar a estimativa global de classificação de 77,9% para 81,6% e 85,2%, respectivamente. A partir dos resultados obtidos pode-se concluir que o código computacional poder ser utilizado para classificar mamões com diferentes graus de maturação e tamanhos durante a pós-colheita. Além disso, está pesquisa reporta pela primeira vez informações sobre a classificação do mamão em relação ao volume e massa utilizando uma metodologia de visão computacional para controle da pós-colheita.

Palavras-chave: Colorimetria, simulação, frutas, pós-colheita.

ABSTRACT

Artificial vision through computational methodologies can be used to classify the fruits efficiently and safely during post-harvest. Brazil is one of the main producers of papaya (*Carica papaya* L.) and the classification of this fruit during post-harvest is mainly done by manual sorting. This study aimed to develop a computational, non-destructive methodology through image analysis to classify papaya (*Carica papaya* L.) based on its state of maturation, taking into account skin color, volume and mass. First, papayas were visually classified according to skin color and volume and mass were determined experimentally. Subsequently, the papaya images were acquired using a digital camera for further processing. The papayas were classified according to the state of maturation, volume and mass, using computational methodologies, in which initially the conversion of the RGB color space to HSV and CIElab was performed, in order to identify the fruit in the image and make estimates of the different parameters. The results obtained experimentally were compared with those obtained computationally. The prediction of the maturation stage had an overall estimate of 95% in relation to the experimental data. In parallel, the estimated volume and mass did not differ statistically from the experimental values, however, the classification based on size (small, medium, and large) presented a better estimate with the estimated volume values ($C (\%) = 90.5$) in relation to the global estimate of the mass ($C (\%) = 77.9$) calculated from the average density ($\bar{\rho}$). Finally, it was possible to improve the estimation of the mass calculation through the use of linear regressions. Through the linear relationship of density with estimated height and volume, it was possible to improve the global classification estimate from 77.9% to 81.6% and 85.2%, respectively. From the results obtained, it can be concluded that the computer code can be used to classify papayas with different degrees of maturation and sizes during post-harvest. In addition, this research reports for the first time information on papaya classification in relation to volume and mass using a computer vision methodology for post-harvest control.

Keywords: Colorimetry, simulation, fruits, post-harvest.

LISTA DE FIGURAS

Figura 1 - Diagrama conceitual integrando visão de máquina, inteligência artificial e pós-colheita.....	16
Figura 2 - Resultados da quantidade de artigos publicados com as palavras-chave “artificial intelligence” e “vision artificial” (a) e os países que mais reportam publicações nesta área. ..	20
Figura 3 - Países com as maiores publicações relacionadas à visão artificial.....	23
Figura 4 - Aspecto visual do mamão ‘Goldem’ representativo em cada estágio de maturação. E1: pele verde sem listra amarela; E2: fruta com 25% da pele amarela e o restante com coloração verde claro; E3: fruta até 50% da superfície amarela envolvida pela coloração verde claro; E4: fruta com 50% a 75% da superfície da pele amarela; E5: fruta com 76 a 100% da superfície amarela, somente a extremidade do pedúnculo é verde.	25
Figura 5 - Diagrama geral de um sistema de visão artificial.....	29
Figura 6 - Espectro visível de cores com linhas espectrais de hidrogênio como referência (MALACARA, 2011).....	30
Figura 7 - Cores primárias: (a) síntese aditiva, (b) síntese subtrativa.	31
Figura 8 - Espaço de cor RGB.....	32
Figura 9 - Espaço de cor HSV.....	33
Figura 10 - Espaço de cor CIE L*a*b*.....	33
Figura 11 - Imagem digital em formato de cor RGB.	35
Figura 12 - Tipos de imagens digitais: (a) imagem RGB, (b) imagem indexada, (c) imagem em tons de cinza, (d) imagem binária.....	35
Figura 13 - Histograma com valores das intensidades.....	39
Figura 14 - Esquema que representa o processo de segmentação.	40
Figura 15 - Eixo menor e maior do contorno C.	42
Figura 16 - Aplicação de área em imagens: (a) área de uma imagem simples (b) uma figura em forma de triângulo.	43
Figura 17 - Mamões em diferentes estágios de maturação: (a) imaturos, (b) semi-maduros, (c) maduros.....	45
Figura 18 - Desenho experimental para captura de imagens, composto por câmera (a), fonte de luz (b), fruta a ser analisada (c), fundo com menos saturação que fruta (d), regra de calibração (e) e uma caixa que isola a luz externa (f).....	46
Figura 19 - Extração de fundo com limiar representado na imagem (a) e histograma (b).....	47

Figura 20 - Pseudocódigo de caracterização do mamão de acordo com seu estado de maturação.....	50
Figura 21 - Interpretação de imagens de acordo com as condições especificadas: (a) mamão imaturo, (b) mamão semi-maduro, (c) mamão maduro.....	51
Figura 22 - Configuração geométrica para seção transversal (a) e seção superior e inferior do mamão (b).....	52
Figura 23 - Pseudocódigo de caracterização do mamão baseado no volume e massa.....	53
Figura 24 - Histogramas de: (a) volume real (V_r) em relação ao volume estimado (V_e) e (b) massa real (M_r) em relação à massa estimada usando a densidade média ($M\rho$).....	56
Figura 25 - Gráficos de dispersão de: (a) volume real (V_r) versus volume estimado (V_e); (b) massa real (M_r) versus massa estimada usando a densidade média ($M\rho$); (c) massa real (M_r) versus massa estimada usando a densidade individual ($M\rho_i$). Bland-Altman representa: (d) a diferença de V_e e V_r (e) $M\rho$ e M_r (f) e $M\rho_i$ e M_r	58
Figura 26 - Gráficos de dispersão de: (a) densidade individual (ρ_i) versus altura estimada (h); (b) densidade individual (ρ_i) versus volume total estimado (V_e); (c) massa em função da altura (Mh) versus massa real (M_r); (d) massa em função do volume (MV) versus massa real (M_r).....	61
Figura 27 - Bland-Altman graficos: (a) a diferença de massa em função da altura (Mh) e da massa real (M_r); e (b) massa estimada usando a densidade média ($M\rho$) e M_r	62

LISTA DE TABELAS

Tabela 1 - Pesquisas realizadas para a medição e predição de parâmetros em vegetais nos últimos 5 anos.....	21
Tabela 2 - Estágios do processamento de imagem digital.	38
Tabela 3 - Matriz de confusão relacionada à classificação da maturação do mamão.....	55
Tabela 4 - Estatística descritiva do volume e massa reais e estimados em mamão.....	57
Tabela 5 - Matriz de confusão para classificação do tamanho do mamão com base em volume e massa.....	60
Tabela 6 - Estatística descritiva da massa reais e estimados em mamão.....	62
Tabela 7 - Análise T-student para amostras relacionadas entre massa estimada e real.....	62
Tabela 8 - Matriz de confusão para classificação do tamanho do mamão usando altura da fruta (Mh) e volume (MV).....	63
Tabela 9 - Estatística descritiva de estimativa de volume e massa com novo conjunto de amostras para validação do código.....	65

LISTA DE ABREVIATURAS E SIGLAS

ε_x : erro experimental

ρ_i : densidade individual (g/mL)

$\bar{\rho}$: densidade média (g/mL)

σ : desvio padrão

σ_{ex} : desvio padrão do erro experimental

B : canal azul (espaço de cor RGB)

B_1 : área circular inferior estimada do cone cortado (cm²)

B_2 : área circular superior estimada do cone costado (cm²)

B_I : determinado valor de azul no espaço de cores RGB

a^* : canal cor de vermelho para verde (espaço de cores CIELab)

b^* : canal de cor de amarelo a azul (espaço de cores CIELab)

C : contorno de um determinado objeto

C_I : determinada cor no espaço de cores RGB

C (%): porcentagem da estimativa correta

d : diâmetro estimado do cone superior/inferior (cm)

$Diam$: diâmetro

f : função bidimensional de uma imagem digital

G : canal verde (espaço de cor RGB)

G_I : determinado valor de verde no espaço de cores RGB

H : canal de matiz (espaço de cor HSV)

h : estimativa de altura total (cm)

h_1 : altura estimada do cone cortado (cm)

h_2 : altura estimada do cone superior/infeior (cm)

IA: inteligência artificial

K : número de classes

L^* : canal de luminosidade (espaço de cores CIELab)

$Max.$: valor máximo

$Min.$: valor mínimo

M_{ρ_i} : massa calculada a partir da densidade individual (g)

$M_{\bar{\rho}}$: massa calculada a partir da densidade média (g)

M_h : massa em função da altura (g)
 M_r : massa de cada mamão medida na balança analítica (g)
 M_V : massa em função do volume (g)
 N : número de pixels do objeto
 n : número de amostras de mamão
 O : objeto a ser analisado em uma imagem digital
 p_i : ponto máximo de um objeto no eixo x
 p_j : ponto máximo de um objeto no eixo y
 R : canal vermelho (espaço de cor RGB)
 R_l : determinado valor de vermelho no espaço de cores RGB
 r_1 : raio estimado da área inferior do corte truncado (cm)
 r_2 : raio estimado da área superior do cone truncado (cm)
 S : canal de saturação (espaço de cor HSV)
 V : canal de valor (espaço de cores HSV)
 V_e : volume total estimado (cm³)
 V_i : volume estimado de cada corte de cone (cm³)
 $V_{top/base}$: volume estimado da parte superior/inferior do cone (cm³)
 V_{max} : valor máximo de um determinado canal no espaço de cores RGB
 V_r : volume real calculado experimentalmente (mL)
 v_f : volume final do recipiente (mL)
 v_i : volume inicial do recipiente (mL)
 X : eixo x do espaço de cor intermediário CIEXYZ
 X_i : distribuição de pontos no espaço bidimensional
 x : eixo horizontal do plano cartesiano de um determinado parâmetro
 x_{min} = coordenada mínima em relação ao eixo x
 x_{max} : coordenada máxima em relação ao eixo x
 y_{min} : coordenada mínima em relação ao eixo y
 y_{max} : coordenada máxima em relação ao eixo y
 Y : eixo y do espaço de cor intermediário CIEXYZ
 y : eixo vertical do plano cartesiano de um determinado parâmetro
 Z : eixo z do espaço de cor intermediário CIEXYZ

SUMARIO

1	INTRODUÇÃO.....	15
1.1	OBJETIVOS.....	17
1.1.1	Objetivo geral	17
1.1.2	Objetivos específicos.....	17
2	ESTADO DA ARTE.....	18
2.1	INTELIGÊNCIA E VISÃO ARTIFICIAL NO MUNDO	18
2.2	INTELIGÊNCIA E VISÃO ARTIFICIAL NA AMÉRICA LATINA	22
2.3	INTELIGÊNCIA E VISÃO ARTIFICIAL NO BRASIL	23
3	MARCO TEÓRICO.....	24
3.1	MAMÃO (<i>CARICA PAPAYA L.</i>).....	24
3.2	SISTEMAS DE VISÃO ARTIFICIAL.....	27
3.2.1	Visão artificial.....	27
3.2.2	Classificação dos sistemas de visão artificial	27
3.2.3	Sistemas de visão artificial na indústria	28
3.3	FUNDAMENTOS DE COR	30
3.3.1	Cores	30
3.4	PROCESSAMENTO DIGITAL DE IMAGENS.....	34
3.4.1	Imagem digital.....	34
3.5	AI E VISÃO ARTIFICIAL NA ANÁLISE E RASTREABILIDADE DE VERDURAS	44
4	MATERIAL E MÉTODOS.....	45
4.1	COLETA DE AMOSTRA	45
4.2	CLASSIFICAÇÃO DE MAMÃO USANDO TRIAGEM MANUAL	45
4.3	AQUISIÇÃO E PROCESSAMENTO DE IMAGENS.....	46
4.4	EXTRAÇÃO DE RECURSOS DE COR DAS IMAGENS	48

4.5	CLASSIFICAÇÃO DO MAMÃO DE ACORDO COM O ESTÁGIO DE MATURAÇÃO	49
4.6	ESTIMATIVA DE VOLUME E MASSA USANDO ANÁLISE DE IMAGEM	51
4.7	ANÁLISE ESTATÍSTICA.....	54
5	RESULTADOS E DISCUSSÃO	55
5.1	CLASSIFICAÇÃO DO MAMÃO DE ACORDO COM O ESTÁGIO DE MATURAÇÃO	55
5.2	ESTIMATIVA DE VOLUME E MASSA.....	56
5.3	VALIDAÇÃO DO CÓDIGO	63
6	CONCLUSÃO	67
6.1	SUGESTÕES DE TRABALHOS FUTUROS.....	67

1 INTRODUÇÃO

Atualmente, a classificação pós-colheita de muitas frutas é feita por triagem manual onde alguns fatores como tamanho, volume, cor e defeitos visuais são usados por pessoas treinadas para classificar as frutas (BOZOKALFA & KILIC, 2010; COSTA et al., 2011; DANG et al., 2010). A triagem manual é uma atividade dispendiosa e demorada, além disso, as frutas são frequentemente danificadas e contaminadas durante esse tipo de classificação (DANG et al., 2010). Essa limitação pode levar a erros de interpretação na classificação de vegetais antes do processamento industrial. Assim, a visão artificial em conjunto com a inteligência artificial são uma alternativa para garantir decisões mais eficientes na área de pós-colheita (Figura 1).

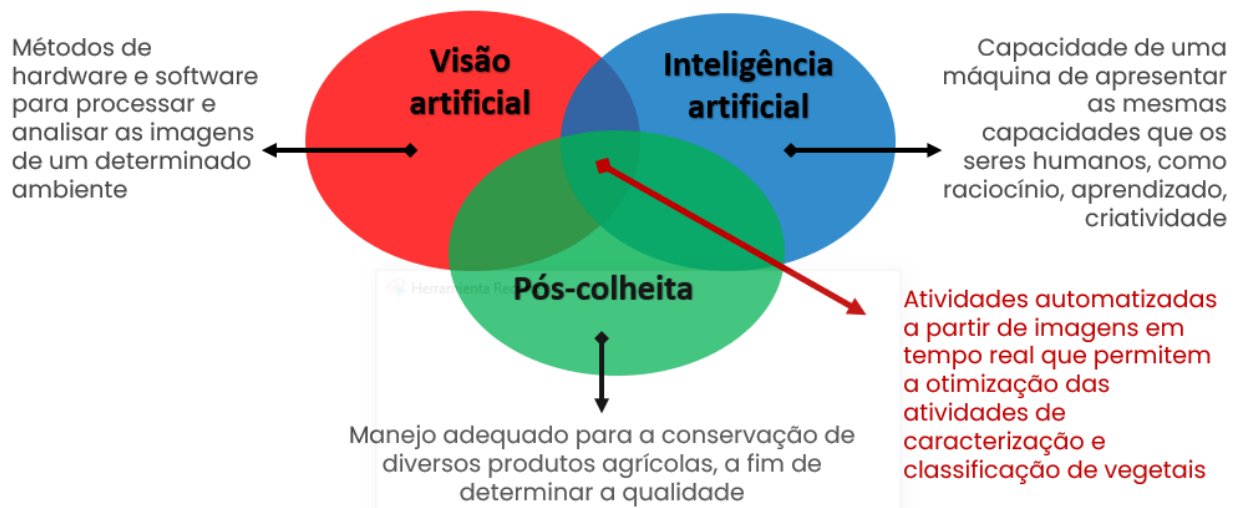
A visão artificial em conjunto com a inteligência artificial surge como uma alternativa aos métodos tradicionais de classificação, para medir ou estimar parâmetros, o que pode garantir objetividade, praticidade, rapidez, eficiência, baixo custo e segurança no processo de classificação das frutas. No campo da agricultura, o número de estudos relacionados ao processamento de imagens e sistemas de visão computacional tem crescido rapidamente, sendo uma importante ferramenta para classificação de frutas na colheita e pós-colheita (ALKREEM & KARIM, 2021; ALOSAIMI et al., 2021; ANANTHANARAYANA et al., 2020; BIFFI et al., 2021). Em geral, a visão computacional tem sido utilizada por meio de diferentes linguagens de programação como C ++, Java, Matlab, *Python*, entre outras. A linguagem de programação *Python* apresenta algumas vantagens quando comparada com outros tipos de programação, pois é uma linguagem de programação multiplataforma, portanto é compatível com Windows, iOS e Linux e é um tipo de código-fonte livre para uso em pesquisas (Chen et al., 2021).

Na literatura, diversas linguagens de programação têm sido desenvolvidas usando visão artificial para classificar e calcular parâmetros de frutas como estágio de maturação, volume e massa em morango, cereja, tomate, pepino e manga, durante sua pós-colheita em escala laboratorial e industrial (CONSTANTE PRÓCEL & GORDÓN GARCÉS, 2015; PANDEY et al., 2014; POUPEAU et al., 2003; VAN ECK et al., 1998; VILLASEÑOR-AGUILAR et al., 2019). A integração quantitativa para classificação e estimativa de parâmetros de frutas é uma tarefa que envolve modelagem física e fisiológica, pois envolve o cálculo de dimensões e estágio de maturação. O interesse na modelagem matemática em dimensões e alteração na qualidade durante o amadurecimento das frutas tem aumentado, pois estes são cada vez mais utilizados na programação, o que tem permitido otimizar processos, fazendo grandes

avanços na classificação automática de objetos (WEGEHENKEL & MIRSCHEL, 2006). É possível, por meio da simulação, avaliar a qualidade das frutas para identificar pontos críticos durante o manejo pós-colheita e ajustar ou melhorar a tomada de decisões relacionadas às datas de colheita e comercialização do produto (VAZQUEZ-CRUZ et al., 2010). Porém, várias frutas ainda são classificadas por triagem manual (SILVA & ABUD, 2017), é o caso do mamão (*Carica papaya* L.), uma fruta climatérica amplamente cultivada em regiões tropicais e subtropicais devido ao seu alto valor nutricional e atratividade sensorial características. O Brasil é o segundo maior produtor e exportador mundial de mamão, alcançando um total de 1.113.614 tom 2019 (FAOSTAT, 2019). Apesar da alta produção e renda gerada pelo mamão no Brasil, ocorre grande perda pós-colheita desse fruta devido à triagem manual (PIGOZZI ET al., 2021). Pesquisas já foram realizadas com o objetivo de melhorar os rendimentos nas fases de pós-colheita do mamão (BEHERA et al., 2021), incluindo pesquisas realizadas no Brasil (PEREIRA et al., 2018).

Na literatura consultada, não foi encontrado nenhum estudo no qual tenha sido desenvolvido um algoritmo computacional para classificar os mamões durante a pós-colheita de acordo com a estimativa massa e o volume.

Figura 1 - Diagrama conceitual integrando visão de máquina, inteligência artificial e pós-colheita.



Fonte: O autor.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Desenvolver uma metodologia computacional, não destrutiva por meio de análise de imagens para classificar o mamão (*Carica papaya* L.) com base na cor da pele, volume e massa.

1.1.2 Objetivos específicos

Classificar os mamões de acordo com o seu estágio de maturação utilizando o espaço de cores HSV e CIElab.

Estimar o volume e a massa usando métodos matemáticos e classificar os mamões de acordo com suas magnitudes.

Otimizar o cálculo da massa usando regressões lineares.

2 ESTADO DA ARTE

Atualmente, a humanidade está presenciando o início da Quarta Revolução Industrial, ou comumente chamada de Indústria 4.0. Essa revolução é marcada pelo surgimento de novas tecnologias como robótica, inteligência artificial, tecnologias cognitivas e nanotecnologia e *Internet of Things*, entre outras. A inteligência artificial (IA) está cada vez mais ligada ao trabalho diário, aos nossos costumes e ao nosso discurso diário, aderindo cada vez mais à cultura de cada uma das regiões do mundo, isto devido às grandes vantagens que nos trouxe, dentre elas, a redução de etapas e a facilidade de atingir uma meta. Os avanços tecnológicos no campo da IA e visão artificial prometem mudar a forma como organizamos o trabalho (ØSTERLUND et al., 2021). No entanto, a integração da IA no ambiente de trabalho continua sendo um desafio em aberto, já que se trata de uma área em constante crescimento.

2.1 INTELIGÊNCIA E VISÃO ARTIFICIAL NO MUNDO

Pelas vantagens que a inteligência artificial traz, o mundo tem optado nos últimos anos por fazer maiores investimentos nesse tipo de tecnologia, que tem gerado um aumento exponencial nas pesquisas e avanços científicos nos últimos 30 anos. As primeiras pesquisas relacionadas à visão artificial surgiram na década de 1950 e, desde então, grandes avanços e descobertas foram feitos (DE FRÍAS, 2019).

O Fórum Econômico Mundial estima que os gastos globais com inteligência artificial ficarão em US\$ 52 bilhões no próximo triênio. Segundo relatório de 2017 da Accenture, estima-se que a inteligência artificial tem potencial para dobrar as taxas de crescimento dos países. O relatório também destacou que até 2035 haverá um crescimento significativo em 16 setores, entre os quais informação e comunicação, manufatura, serviços financeiros, transporte, alimentação e saúde (ACCENTURE, 2020).


Até o ano de 2021, os EUA lideram em implementação de IA e visão artificial, com 40% das empresas de inteligência artificial presentes no país e com mais de 16 agências governamentais que apoiam financeira e politicamente essas empresas. A China se posiciona em segundo lugar, com 11% das empresas ligadas ao tema e prevê que até 2030 será a líder mundial em IA e visão artificial. Israel, Reino Unido e Canadá estão em terceiro, quarto e quinto

lugares com 11%, 7% e 3,8%, respectivamente, de participação no mercado de IA e visão artificial. O Brasil é o único país da América Latina que aparece no ranking, localizado na 17ª posição (RESET, 2020) Segundo estudos da consultoria FrontierView, encomendada pela Microsoft, o produto interno bruto do Brasil poderia crescer até 4,2% se os modelos de inteligência artificial fossem adotados massivamente, obtendo um aumento de 1,8% em um cenário mais conservador. A consultoria de inteligência de mercado IDC viu um aumento nos projetos de IA nas empresas. Um gasto de 464 milhões de dólares – na faixa de 2,4 bilhões de reais – foi projetado no Brasil com essa área em 2021.

Os tipos de aplicativos de IA e visão artificial variam de acordo com as tecnologias usadas. Entre as aplicações mais estudadas e utilizadas estão os tipos de *Machine Learning*, Processamento de Linguagem Natural (PNL) (Puerta-Díaz et al., 2021).

De acordo com a base de dados SCOPUS, desde 2000 tem-se observado um crescimento exponencial na produção de artigos relacionados com IA e visão artificial, mostrando a relevância destes temas nos últimos anos (Figura 2a). Os EUA é o país que mais pesquisas tem realizado, com quase 7 mil artigos científicos publicados desde 1990, seguidos da China, Reino Unido, Alemanha e Índia (Figura 2b). De acordo com o Nature Index, as universidades que se destacam na pesquisa de IA são Harvard University, Stanford University, Massachusetts Institute of Technology, Oxford University e Cambridge University, com 937, 629, 620, 495 e 485 artigos publicados, respectivamente, de 2015 a 2019 (NATURE INDEX, 2020). Entre as aplicações utilizadas para a visão artificial está o processamento de imagens, que permite, por exemplo, a classificação de objetos como vegetais, frequentemente realizados na indústria de alimentos (BHARGAVA & BANSAL, 2021A; HASSAN & NASHAT, 2019). Nos últimos anos, diversas pesquisas têm sido realizadas para implementar ou melhorar sistemas de classificação de vegetais, que podem ser baseados em tamanho, volume, massa, estágio de maturação, etc. (Tabela 1). Estas pesquisas têm sido feitas com mais frequência em tomates, laranjas e mangas, utilizando linguagens de programação MATLAB, *Python* e C ++.

Figura 2 - Resultados da quantidade de artigos publicados com as palavras-chave “*artificial intelligence*” e “*vision artificial*” (a) e os países que mais reportam publicações nesta área.



Fonte: Adaptado da SCOPUS.

A inserção da inteligência artificial em diversas áreas tem promovido a diminuição de alguns tipos de emprego na área de manufatura. No entanto, os avanços da tecnologia com a IA têm promovido a criação de novos tipos de empregos em profissões que ainda não existem ou surgiram recentemente (EUROPEAN COMMISSION, 2021).

Tabela 1 - Pesquisas realizadas para a medição e predição de parâmetros em vegetais nos últimos 5 anos.

Vegetais	Software/Language m de programação	Parâmetro de medição	Autor
Maracujá	C++	Massa e volume	BONILLA et al., 2017
Kiwi	Não especificado	Comprimento, diâmetro máximo do equatorial	FU et al., 2016
Cenoura e pepino	MATLAB R2019a	seção, área projetada e volume	HUYNH et al., 2020
Manga	G-language	Tamanho, massa e volume	IBRAHIM et al., 2016
Batata, limão e tomate	Matlab 2018a	Forma, volume e massa	JANA et al., 2020
Laranja Bam, Laranja Khooni, e Laranja Thompson	MATLAB R2009b	Volume e massa	JAVADIKIA et al., 2017
Tomate	Python	Massa	DE LUNA et al., 2019
Tomate cereja	MATLAB R2019a	Tamanho	NYALALA et al., 2019
Manga	MATLAB 2012b	Volume e massa	UTAI et al., 2019
Cantalupo Golden Apollo	Python	Massa	AHMAD, 2017
Maçã e manga	MATLAB	Previsão de maturação	ALI & THAI, 2017
Tomate	MATLAB	Presença de defeitos	ARAKERI & LAKSHMANA, 2016
Mamão	MATLAB 2019a	Defeitos e estágio de maturação	BEHERA et al., 2021
Maçã	ImageJ v. 1.47	Previsão de maturação	CÁRDENAS- PÉREZ et al., 2017
Groselha do cabo	Não especificado	Previsão de maturação	CASTRO et al., 2019
Tomate	MATLAB	Previsão de maturação	GARCIA et al., 2019
Tomate	Não especificado	Defeitos e estagio de maturação	IRERI et al., 2019
Grape	Não especificado	Previsão de maturação	KANGUNE et al., 2019

Fonte: O autor.

2.2 INTELIGÊNCIA E VISÃO ARTIFICIAL NA AMÉRICA LATINA

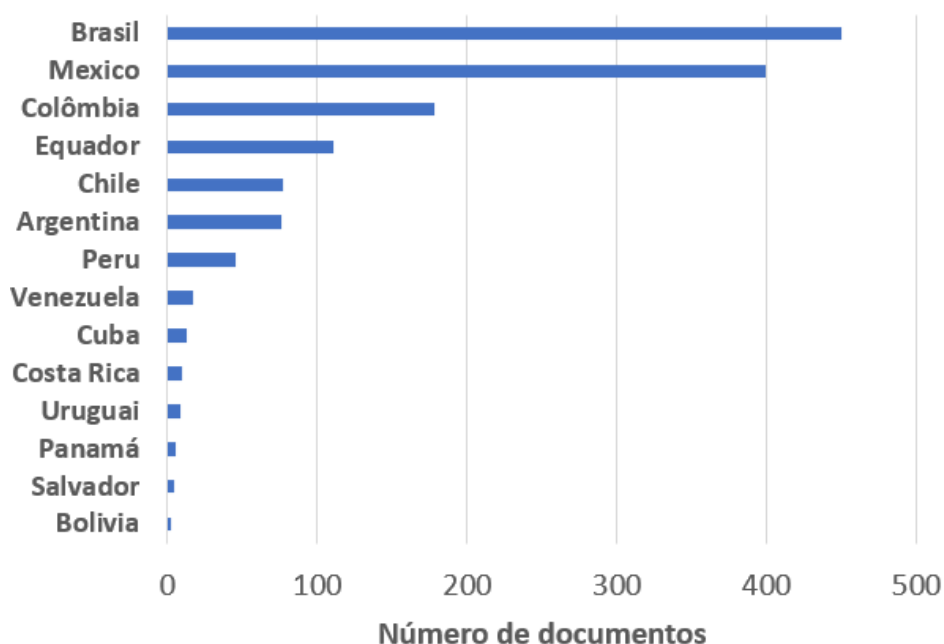
Atualmente, 17% da população mundial carece dos benefícios oferecidos pela Segunda Revolução Industrial (eletricidade), E mais da metade da população mundial ainda não tem uma conexão de internet de boa qualidade (CORVALÁN, 2018). A falta de conectividade predomina em grande parte dos países latino-americanos, pois aproximadamente 70% da população, em média, tem acesso à internet (C MINDS, 2020). A Comissão Econômica para a América Latina e o Caribe informou que a tecnologia pode ser até 10 vezes menor nas áreas rurais em comparação com as áreas urbanas (C MINDS, 2020).

O atraso no progresso nos países do terceiro mundo é geralmente causado pela necessidade de enfrentar desafios básicos, como o acesso à água ou a outros serviços essenciais. Isso cria a necessidade de priorizar outros projetos do governo antes de tomar iniciativas para outros, como a IA e/ou visão artificial (CORVALÁN, 2018). No entanto, esse tipo de situação não impediu que os países latino-americanos continuassem avançando na transição para as novas tecnologias.

Os países latino-americanos atualmente possuem uma estratégia de avanço digital. Uruguai e Colômbia já desenvolveram suas estratégias nacionais de IA, enquanto Brasil e Chile estão em planejamento, e México e Argentina têm feito esforços significativos para incluir em seus ecossistemas desenvolvimentos em inteligência artificial que ainda não foram consolidados. Aproximadamente 75% das melhores universidades da América Latina possuem centros de pesquisa e desenvolvimento de sistemas automatizados (C MINDS, 2020).

A América Latina, assim como o restante dos continentes, teve um crescimento exponencial na produção de artigos científicos relacionados à visão artificial, em que o Brasil se destacou em primeiro lugar com o maior volume de artigos produzidos desde 1990, seguido por México, Colômbia, Equador e Chile (Figura 3), demonstrando a importância deste tema para a automação de processos. Segundo a base de dados SCOPUS, a visão artificial tem sido pouco estudada na América Latina para ser implementada na área de classificação de vegetais, representando aproximadamente 3% da produção científica em inteligência artificial. Portanto, trata-se de um incentivo para reforçar a IA aplicada a vegetais, já que a América Latina é o continente com maior produção e diversidade em vegetais (ECLAC, 2014).

Figura 3 - Países com as maiores publicações relacionadas à visão artificial.



Fonte: Adaptado da SCOPUS.

2.3 INTELIGÊNCIA E VISÃO ARTIFICIAL NO BRASIL

O Índice de Adoção Digital 2019 do Banco Mundial classificou o Brasil em 12º lugar entre os países da América Latina e 43º em 180 países em todo o mundo. No entanto, em termos de utilização das Tecnologias da informação e comunicação (TICs), o Brasil ocupa a sexta posição entre os países latino-americanos e a 72ª entre 129 países no mundo, segundo o Índice de Prontidão de Redes do Fórum Econômico Mundial (C MINDS, 2020).

Em 2017, foi relatado que o Brasil atingiu 69% de acessibilidade à internet em sua população (UNESCO, 2019). O crescimento da concentração para 68% da população em áreas urbanas tem sido um dos fatores que tem facilitado o aumento do acesso à internet nos últimos anos (C MINDS, 2020). O governo nacional ofereceu incentivos na forma de concursos e prêmios para motivar este setor. Isso tem permitido o surgimento de empresas movidas pela inteligência artificial e visão artificial, principalmente nos setores de FinTech e AgroTech, cada vez mais importantes internacionalmente. Os incentivos do governo brasileiro para aumentar a conectividade promoverão maiores benefícios da revolução da indústria de quarta geração (digitalização) (C MINDS, 2020).

O Brasil possui renomados centros regionais de pesquisa e educação, que têm promovido o desenvolvimento e a inovação em áreas relacionadas à IA e visão artificial. O país possui universidades de prestígio que oferecem programas de IA, como a Universidade Federal de Minas Gerais (UFMG). Esta universidade tem sido uma importante entidade para o crescimento e desenvolvimento da IA a nível nacional e tem contribuído para projetos importantes. A Universidade Federal de Santa Catarina (UFSC) possui um conceituado laboratório de pesquisas em IA que também tem possibilitado a realização de projetos relevantes (C MINDS, 2020).

Levando em consideração que o Brasil é o segundo maior exportador de frutas do mundo com uma participação de 10% (FAO, 2019b), seria de grande benefício investir em IA com foco em visão artificial para melhorar a qualidade de seleção e processamento de vegetais, o que poderia promover um maior investimento estrangeiro.

3 MARCO TEÓRICO

3.1 MAMÃO (*CARICA PAPAYA* L.)

A fruta do mamão é uma baga ovóide, cuja forma varia de quase esférica a oblonga ou periférica. Possui uma cavidade cujo tamanho pode ser menor ou maior que a metade do diâmetro da fruta. Esta cavidade contém as sementes que podem ser muito numerosas ou praticamente inexistentes. A fruta madura contém cerca de 85% de água, 10 a 13% de açúcares, 0,6% de proteína, é rica em vitamina A e contém quantidades adequadas de vitaminas B1, B2 e C (FAO, 2007). A pele é fina e lisa, protegendo uma polpa com 2,5 cm a 5 cm de espessura e de coloração que pode variar de verde a amarela (Figura 4). Esta figura mostra cinco estágios de maturação de acordo com o estudo realizado por OLIVEIRA et al., (2015), iniciando com a dominância do verde ao amarelo no estágio final no caso do mamão ‘Goldem’. O mamão ‘Goldem’ também foi caracterizado em diferentes estágios de maturação, variando de 5 a 8 estágios (FABI et al., 2010; PEIXOTO, 2008; REIS NETO, 2006). Embora esta fruta se caracterize em vários estágios de maturação, geralmente não é necessário realizar um processo de classificação com mais de três estágios em uma indústria (verde, semi-maduro e maduro), pois isso depende apenas de sua continuidade no linha de processo para processamento ou distribuição ao consumidor.

Figura 4 - Aspecto visual do mamão ‘Goldem’ representativo em cada estágio de maturação.

E1: pele verde sem listra amarela; E2: fruta com 25% da pele amarela e o restante com coloração verde claro; E3: fruta até 50% da superfície amarela envolvida pela coloração verde claro; E4: fruta com 50% a 75% da superfície da pele amarela; E5: fruta com 76 a 100% da superfície amarela, somente a extremidade do pedúnculo é verde.



Fonte: OLIVEIRA et al. (2015).

A qualidade do mamão depende de seu estado de saúde e de sua aparência geral. A fruta não deve conter danos e defeitos questionáveis do ponto de vista comercial e sanitário. Sua maturação deve ser tal que possa ser comercializada em um prazo razoável e que atenda às necessidades do consumidor (FAO, 2007). Além disso, os parâmetros que descrevem o tamanho também são um fator de qualidade, que pode ser descrito em termos de volume e massa, uma vez que a aceitação dessa fruta dependerá das exigências do comprador. Além do volume e da massa, existem outros tipos de caracterizações organolépticas do mamão que podem descrever sua qualidade, como textura, sabor e cheiro, e estes são fatores críticos, pois podem ser correlacionados com o estado de saúde e maturação do mamão dessa fruta.

As variações dessas características dependem em grande parte do processo de amadurecimento que pode ser descrito pelo processo de produção de etileno em mamão. O mamão tem alto índice de produção de etileno e aumento da taxa respiratória após a colheita, o que o agrupa no tipo de fruta climatérica (BRON et al., 2006). Esse processo permite o amadurecimento da fruta, causando alterações em suas características, promovendo alterações tanto na cor da pele quanto em sua composição nutricional (FABI & DO PRADO, 2019; MELO, 2019). A cor característica da pele e da polpa do mamão maduro (amarelo ou

laranja/vermelho) deve-se aos diferentes tipos de carotenoides. Em geral, as variedades laranja/vermelha possuem quantidades relativamente altas de licopeno, que é um composto central no metabolismo dos carotenoides durante o amadurecimento do mamão e é responsável pela cor vermelha não apenas no mamão (BARRETO et al., 2011), mas também no tomate (ARIAS et al., 2000), goiabas (ROJAS-GARBANZO et al., 2017) e melancias (PERKINS-VEAZIE et al., 2006). A maioria dos mais de 600 carotenoides naturais (SIGURDSON et al., 2017) são originários da via do metileritritol 4-fosfato (MEP). Para cultivares de mamão 'Golden', all-trans-licopeno foi o principal carotenoide em estágios iniciais e all-trans- β -criptoxantina foi o principal carotenoide em frutas maduros (MARTINS et al., 2016). A ciência e a tecnologia baseadas nas características organolépticas do mamão tem permitido amplo conhecimento em seu manejo no Brasil, atendendo padrões de qualidade desde a colheita até o consumo, o que tem permitido a internacionalização deste produto.

Nos últimos 50 anos, a produção mundial de mamão cresceu significativamente, tanto em termos de rendimento como de volumes de produção. O mamão geralmente é consumido fresco e é produzido principalmente na América do Sul e na Ásia. Aproximadamente, 37% do mamão produzido no mundo é fornecido pela América (FUENTES & SANTAMARÍA, 2014). Brasil e México pertencem aos 5 maiores exportadores de mamão. A exportação da fruta *in natura* ainda é considerada baixa quando comparada a outras frutas, principalmente devido a problemas e deficiências no transporte. Apesar do ligeiro aumento no volume das exportações de 1% em 2019, quando comparado ao ano anterior, em 2019 a quantidade exportada foi considerada maior (43,3 mil kg), em um período de cinco anos (Braga, 2020).

Segundo a FAO (2019), o Brasil é o segundo maior produtor mundial de mamão papaia, com aproximadamente 1.113.614 toneladas produzidas em 2019, sendo a Europa o principal mercado de exportação desta fruta (FAO, 2019a). Segundo dados da Empresa Brasileira de Pesquisa Agropecuária, em termos de produção nacional constata-se que os principais estados produtores de mamão são Espírito Santo, Bahia, Ceará, Rio Grande do Norte e Minas Gerais, com 354, 337, 100, 81 e 50 mil toneladas produzidas, respectivamente, no ano de 2018 (FLÔR VIEIRA, 2020).

Apesar do mamão ser uma fruta altamente produzida e exportada, ainda existem desafios para preservar seu estado de qualidade, tendo em consideração que essa fruta tem uma pele muito fina que pode ser facilmente danificada, sendo suscetível à entrada de microrganismos. Portanto, é necessário implementar processos de pós-colheita em que seja

necessário evitar ou reduzir o manuseio, para a prevenção de danos e infecções. Uma solução alternativa que já vem sendo implementada em diversas frutas, é a implementação de automação de processos por meio de IA utilizando sistemas visão artificial para medição e classificação (BHARGAVA & BANSAL, 2021B; LI et al., 2019).

3.2 SISTEMAS DE VISÃO ARTIFICIAL

3.2.1 Visão artificial

Com o passar do tempo, a humanidade tem tentado dar à máquina a capacidade de se comportar como uma pessoa, tentando dar-lhe habilidades como analisar, resolver problemas e da mesma forma tem trabalhado intensamente para dar à máquina a capacidade de ter sentidos, como a visão. Com esta iniciativa, tem-se realizado investigação e desenvolvimento da visão computacional ou visão artificial para atingir o objetivo de simular o sentido da visão do ser humano, tendo como referência uma das frases ditas “Se o computador deve enfrentar o mundo humano, ele deve ter a capacidade de ver” (ATENCIO ORTÍZ, 2009).

Visão artificial, então, é a capacidade de uma máquina para tratar ou analisar uma ou mais imagens em seu ambiente, com o objetivo de desenvolver automaticamente uma determinada tarefa (RODRIGUEZ MORALES & SOSSA AZUELA, 2011).

Em geral, um sistema de visão artificial possui 3 processos: aquisição, processamento e interpretação de imagens. Embora a IA não interfira no processo de digitalização da imagem, ela desempenha um papel importante na sua interpretação, embora deva ser destacado que a IA não é essencial em um sistema de visão artificial (CHANCO GAMONAL, 2020).

3.2.2 Classificação dos sistemas de visão artificial

Os sistemas de visão artificial podem ser classificados em dois grandes grupos, sistemas de visão bidimensionais e tridimensionais.

3.2.2.1 Sistemas de visão bidimensional

Como o próprio nome indica, trata-se de sistemas que processam imagens em duas dimensões, planas, e embora sejam mais utilizadas, apresentam alguns problemas como a sobreposição de objetos, a necessidade de um ambiente com iluminação controlada para conseguir uma imagem de boa qualidade, assim como a necessidade de usar imagens binárias para obter contornos e formas de objetos, entre outros (CUBERO et al., 2014).

3.2.2.2 Sistemas de visão tridimensional

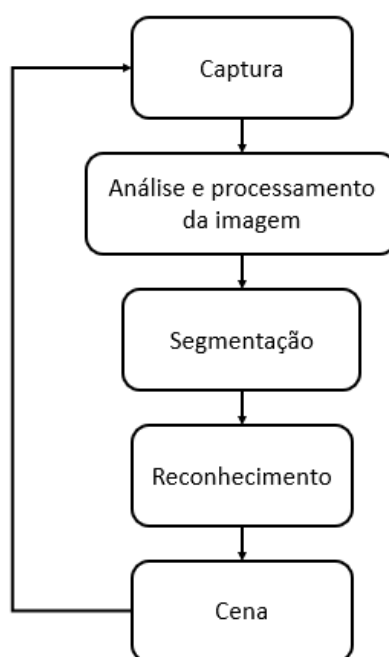
Esses tipos de sistemas tentam corrigir os problemas dos sistemas de visão bidimensional, como a sobreposição que ocorre na visão 2D. A visão tridimensional tem permitido grandes avanços e aplicabilidade tanto na medicina, na cirurgia moderna, nas varreduras cerebrais, quanto na arquitetura para a reconstrução de ambientes a partir de imagens estereoscópicas (GÓMEZ-SANCHIS et al., 2008).

3.2.3 Sistemas de visão artificial na indústria

O desenvolvimento de sistemas de visão artificial requer de diversas técnicas e disciplinas, que podem ser administradas geralmente em carreiras como engenharia eletrônica (design de hardware e software), engenharia, matemática, física (óptica e luminosidade) e engenharia mecânica (quando sistemas de visão artificial interagem com o mundo mecânico) (BLASCO et al., 2010). A Figura 5 apresenta os componentes que geralmente são observados em um sistema de visão artificial, com o passo a passo necessário para extrair as informações de uma imagem. Em primeiro lugar está a captura de imagens, que pode ser feita com dispositivos de vídeo (câmeras digitais, celulares, computadores, scanners, etc.), que criam imagens compatíveis com a leitura do software de programação. Em seguida, as imagens são processadas pelo software, lendo-as com um formato padrão que geralmente é o espaço de cores RGB. Nesta etapa as imagens podem ser alteradas para outros espaços de cores (HSV, CMYK, CIElab, etc.), modificar seu tamanho, fazer cortes, zoom, entre outras modificações. Em seguida vem a segmentação de imagem, que envolve a divisão de uma imagem digital em vários segmentos de imagem, também conhecidos como regiões de imagem ou objetos de imagem

(matrizes de pixels). O objetivo da segmentação é simplificar e/ou alterar a representação de uma imagem em algo mais significativo e mais fácil de analisar. Mais precisamente, a segmentação de imagem é o processo de atribuir um rótulo a cada pixel em uma imagem para que os pixels com o mesmo rótulo compartilhem certas características. Um tipo bem conhecido de segmentação é o *thresholding* ou limiarização, no qual o objetivo é converter uma imagem em tons de cinza para uma nova com apenas dois níveis, de modo que os objetos fiquem separados do fundo. E em último lugar está o reconhecimento e cena, em que o software interpreta as imagens de acordo com as condições que foram colocadas no algoritmo.

Figura 5 - Diagrama geral de um sistema de visão artificial.



Fonte: O autor.

3.2.3.1 Visão computacional para a agroindústria

O objetivo de colocar em prática sistemas de visão artificial em processos agroindustriais é estimar ou simular um ou vários parâmetros de interesse nos produtos para relacioná-los aos padrões de qualidade exigidos pelo consumidor. Por outro lado, outros sistemas de visão artificial têm como objetivo determinar a forma como os produtos evoluem em função do tempo, a fim de saber se os tratamentos utilizados são adequados ou se um produto está sofrendo alterações (PATTNAYAK & PATRA, 2020). Na maioria das aplicações,

a visão computacional é usada para avaliar parâmetros como forma, tamanho, cor, textura, estágio de maturação ou detecção de danos (CUBERO GARCÍA, 2012). A estimativa de parâmetros em mamão poderia contribuir para a rastreabilidade do produto na fase pós-colheita. Essa medida poderia ajudar a manter a segurança alimentar, dificultando a chegada de alimentos não conformes ao consumidor. Permitiria também conhecer a origem dos produtos e desta forma, seria possível distinguir de forma eficaz, onde as boas práticas de produção não estão sendo realizadas.


Dada a necessidade de garantir padrões de qualidade para a satisfação das exigências do cliente, todo processo é avaliado quanto à qualidade final do produto; e para ter uma análise eficaz, a revisão manual dos produtos tem evoluído devido aos avanços tecnológicos relacionados com a inspeção automática, passando de um trabalho lento, inconsistente, especulativo e deficiente, para processos de inspeção rápidos, ininterruptos e competitivos, de melhor qualidade e com maior produtividade e redução de custos (CONSTANTE PRÓCEL & GORDÓN GARCÉS, 2015).

3.3 FUNDAMENTOS DE COR

3.3.1 Cores

A cor é uma característica do ambiente que percebemos quando há luz. A luz é composta por ondas eletromagnéticas que se propagam a uma velocidade de 300 mil km/s, as ondas se caracterizam pelo comprimento, dando assim variedade aos diferentes tipos de luz, algumas são percebidas pelo olho humano que estão entre 380 e 770 nanômetros como mostra a Figura 6 (GARCÍA SANTILLÁN, 2008).

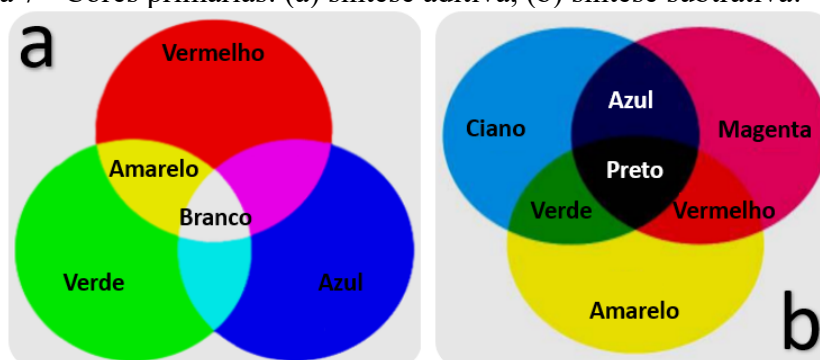
Figura 6 - Espectro visível de cores com linhas espectrais de hidrogênio como referência (MALACARA, 2011).



Fonte: MALACARA (2011).

As cores percebidas pelo olho humano podem ser recriadas através da combinação de três cores, então chamadas de cores primárias. As cores primárias são aquelas que, combinando, produzirão todas as cores do espectro visível. Existem dois sistemas de cores primárias que são cores luz (síntese aditiva) e cores de pigmento (síntese subtrativa). As cores luz são baseados nas cores primárias, vermelho, verde e azul (RGB), e são emitidos por luzes (celular, televisão, computador, etc.), é cuja função eles podem criar e compor a luz branca conforme observado na Figura 7a. Por isso é considerada síntese aditiva e as combinações parciais dessas luzes dão origem às cores do espectro visível (GARCÍA SANTILLÁN, 2008). E as cores pigmento são compostos de magenta, ciano e amarelo. A combinação desses três pigmentos resulta na cor preta, como pode ser visto na Figura 7b, produzindo a cor mais escura e com a menor quantidade de luz, por isso é considerada síntese subtrativa. Na prática, o pigmento preto é adicionado para obter uma cor mais intensa, obtendo um espaço de cor CMYK (GARCÍA SANTILLÁN, 2008).

Figura 7 - Cores primárias: (a) síntese aditiva, (b) síntese subtrativa.



Fonte: IBRAHEEM et al., (2012).

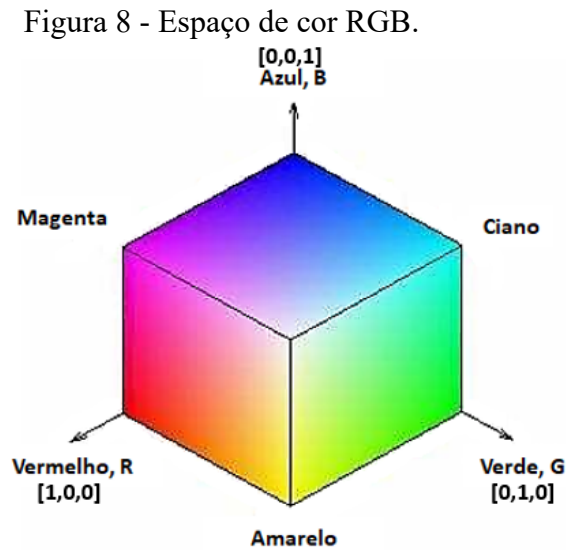
3.3.1.1 Espaços de cor

3.3.1.1.1 Espaço de cor RGB

O espaço de cores RGB formam um cubo, no qual seus eixos correspondem às três cores primárias R, G e B. Os valores RGB são restritos: são positivos e têm valores de $[0, V_{max}]$, onde normalmente $V_{max} = 255$. Cada cor possível (C_I) estará contida no cubo RGB, com os componentes: (CUEVAS et al., 2010).

$$C_I = (R_I, G_I, B_I) \quad (1)$$

A Figura 8 mostra o espaço de cores RGB em forma de cubo, onde normalmente o intervalo de valores das componentes de cor são normalizados ao intervalo $[0,1]$, obtendo-se um cubo unitário, no ponto $[0,0,0]$ representa preto, o ponto $[1,1,1]$ representa branco.

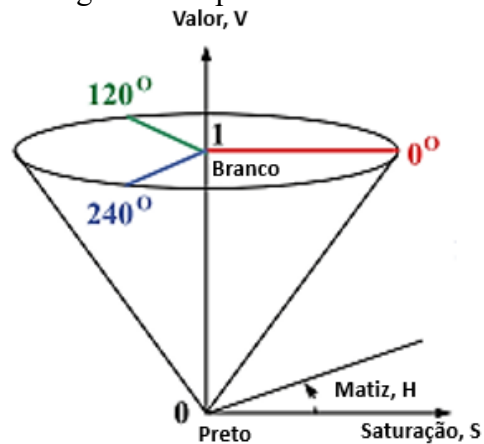


Fonte: VAN DEN BROEK (2005).

3.3.1.1.2 Espaço de cor HSV

Este espaço de cores exibe informações de cores usando três canais ou componentes H (matiz), S (saturação) e V (valor). O espaço de cores do HSV é representado por um cone invertido conforme mostrado na Figura 9. Matiz é o atributo básico da cor, que é o nome da cor usual, como vermelho e amarelo. Este canal é representado no eixo radial do cone, seus valores variam de 0 a 360° e gira em torno de todas as cores do espectro visível. A saturação refere-se à pureza da cor, que se encontra horizontalmente tomando o canal de valor como eixo. Quanto maior esse parâmetro, mais puro ele é, e quanto menor ele se transformará gradualmente em tons de cinza ou próximos ao branco, onde seus valores variam de 0 a 100%. E o canal de valor representa a altura no eixo vertical preto-branco. Os valores possíveis variam de 0 a 100%, onde 0 é sempre preto. Dependendo da saturação, 100 podem ser brancos ou uma cor mais ou menos saturada. Em algumas linguagens de programação como *Python*, os três canais são representados de 0 a 256.

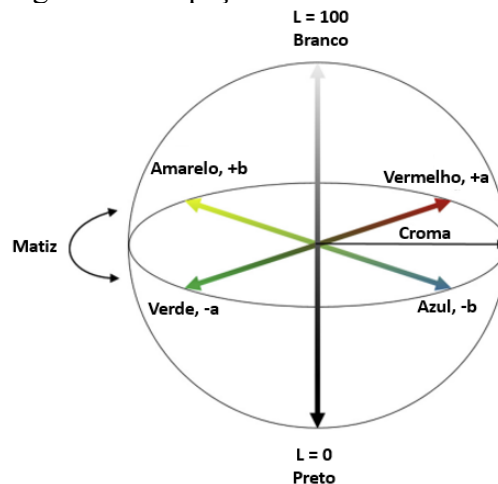
Figura 9 - Espaço de cor HSV.



Fonte: CHEN et al. (2017).

3.3.1.1.3 Espaço de cor $L^*a^*b^*$

O espaço de cores $L^*a^*b^*$ foi criado com o objetivo de linearizar a relação de mudança de posição contra mudança de tonalidade, para que o ser humano percebesse essas mudanças, construindo um modelo mais intuitivo. Este modelo é composto por três canais, L^* (luminosidade) que representa o brilho (0 a 100), a^* (coordenada vermelho/verde) que inclui as cores verdes com valores negativos até os valores positivos correspondentes ao vermelho (-60 a 60), enquanto o valor de b^* (coordenada amarelo/azul) que representa valores negativos correspondendo ao azul ao amarelo com valores positivos (-60 a 60) (Cuevas et al., 2010).

Figura 10 - Espaço de cor CIE $L^*a^*b^*$.

Fonte: LY et al. (2020).

3.3.1.1.4 Espaço de CIE XYZ

Um dos primeiros espaços de cores definidos é o CIE XYZ, também conhecido como as funções tristimulares X, Y e Z, e como o espaço de cores CIE; XYZ é criado pela comissão internacional de iluminação de 1931. Matematicamente falando, o modelo pode ser descrito como o componente de luminância Y juntamente com duas coordenadas de cromaticidade X e Z (IBRAHEEM et al., 2012). Esse espaço de cor é comumente usado como intermediário para a conversão entre esses espaços de cores. Como exemplo, ao converter de RGB para CIE XYZ, este último geralmente é chamado de sRGB, como prova de que vem do espaço de cores RGB. Tendo em conta que os softwares de programação costumam ler imagens em formato RGB, normalmente são feitas conversões para espaço de cores HSV, CIElab, entre outros.

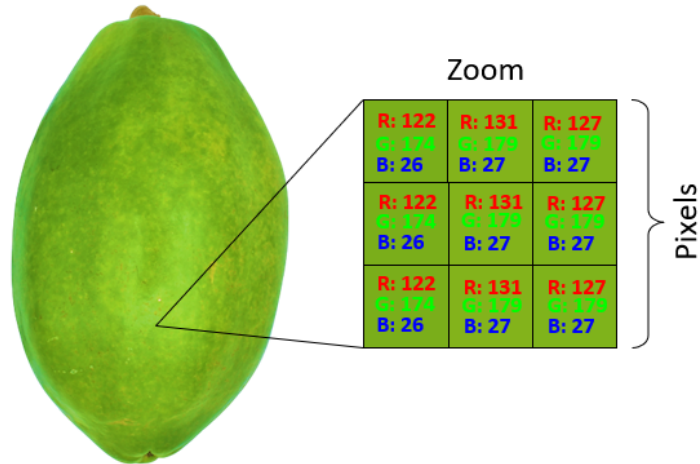
3.4 PROCESSAMENTO DIGITAL DE IMAGENS

O processamento de imagens digitais é um conjunto de etapas que se inicia a partir de imagens do mundo real obtidas digitalmente com o auxílio de um dispositivo conectado a um computador para armazenamento, transmissão ou respectivo tratamento (RODRIGUEZ MORALES & SOSSA AZUELA, 2011).

3.4.1 Imagem digital

É uma função bidimensional $f(x, y)$ onde x e y são coordenadas no plano e a amplitude f é chamada de intensidade ou nível de cinza naquele ponto. Quando (x, y) e f são finitos (quantidades discretas), chamamos a função como uma imagem digital (Figura 11). Em outras palavras, uma imagem digital será composta por um número finito de elementos chamados pixels, cada um dos quais possui um determinado valor e posição (GARCÍA SANTILLÁN, 2008).

Figura 11 - Imagem digital em formato de cor RGB.




Fonte: O autor.

3.4.1.1 Tipos de imagens digitais

As imagens digitais são geralmente classificadas em quatro tipos: RGB, imagens indexadas, imagens em tons de cinza e imagens binárias (Figura 12) (GARCÍA SANTILLÁN, 2008). O tipo de imagem digital a ser utilizada dependerá do interesse, por isso cada tipo de imagem é explicado a seguir.

Figura 12 - Tipos de imagens digitais: (a) imagem RGB, (b) imagem indexada, (c) imagem em tons de cinza, (d) imagem binária.



Fonte: O autor.

3.4.1.1.1 Imagens RGB (Red-Green-Blue)

As imagens RGB são baseadas na composição de cores combinando vermelho (R), verde (G) e azul (B). O modelo RGB é um formato de cor aditivo, ou seja, a combinação de cores é baseada na adição dos componentes individuais, tomando por base a cor preta (CUEVAS et al., 2010). As características de uma imagem RGB são: utilizam três canais para reproduzir as cores na tela, utilizam 8 bits por canal (8 bits x 3), ou seja, 24 bits de cor para cada pixel e suporta formatos como JPG, BMP, PNG, etc. (GARCÍA SANTILLÁN, 2008). A Figura 12a mostra um exemplo de imagem RGB, ela é composta por 3 camadas que são: vermelho, verde e azul, que compõem a cor da imagem.

3.4.1.1.2 Imagens indexadas

Uma imagem indexada deve conter um número restrito de cores, que é formado por dois componentes: a matriz de dados e um mapa de paleta de cores (Figura 12b) (CUEVAS et al., 2010). As imagens indexadas têm as seguintes características: reduzem as cores da imagem a um máximo de 256, suportam GIF, PNG-8 e muitos aplicativos de multimídia, esses formatos são leves para armazenamento e reduzem o tamanho do arquivo eliminando informações de cor (GARCÍA SANTILLÁN, 2008).

Uma imagem em tons de cinza é descrita por uma matriz em que seus valores foram escalados para representar um certo número de intervalos (CUEVAS et al., 2010). As imagens em tons de cinza são descritas com as seguintes características: utilizam uma gama de cores de cinza, em uma imagem com profundidade de 8 bits, podem ter valores de até 256 tons de cinza e cada pixel possui um valor entre 0 (preto) e 255 (branco). A Figura 12c mostra uma aplicação de uma imagem em tons de cinza na faixa de [0 255], mas esses valores estão em uma única camada, ao contrário do modelo RGB, que é de 3 camadas.

3.4.1.1.3 Imagens binárias

Uma imagem binária possui um arranjo que contém apenas zeros e uns, ou seja, os uns e zeros são valores que indicam o estado de falso (0) e verdadeiro (1) (CUEVAS et al., 2010). A Figura 12d mostra uma aplicação de uma imagem binária, independentemente do método de segmentação utilizado, obtém-se o zero (cor branca), considerando o objeto e o valor de 1 (preto) é o fundo da imagem.

3.4.1.2 Etapas do processamento de imagens

Essas etapas podem ser subdivididas em seis áreas principais, e são agrupadas de acordo com a complexidade e delicadeza de sua interpretação, conforme mostrado na Tabela 2. Três níveis de processamento foram considerados: visão de baixo, médio e alto nível (GARCÍA SANTILLÁN, 2008).

3.4.1.2.1 Captura ou aquisição

Esta é a etapa inicial do processamento da imagem digital, que consiste na obtenção de uma imagem por meio de um dispositivo de captura, como câmera digital, scanner, câmera de vídeo, satélite, etc. (RODRIGUEZ MORALES & SOSSA AZUELA, 2011).

Nesta pesquisa, foi utilizada uma câmera digital, portanto é importante conhecer suas características mais importantes, como: resolução da imagem e memória de armazenamento. A resolução de uma imagem indica a quantidade de detalhes que podem ser observados nela. O termo é comumente usado em relação a imagens de fotografia digital, mas também é usado para descrever a nitidez de uma imagem digital. A resolução de uma imagem digital contém um certo número de pixels que simula as cores de um determinado ambiente ou objeto, em algumas câmeras é possível configurar e utilizar diferentes resoluções (GARCÍA SANTILLÁN, 2008). E a memória de uma câmera digital é o dispositivo que retém, memoriza ou armazena dados informáticos na forma de imagens ou vídeos, quanto maior sua capacidade de armazenamento, mais informações pode conter e pode ser baixado para um computador. As câmeras digitais incorporam memória interna, mas memórias expansíveis podem ser adicionadas (GARCÍA SANTILLÁN, 2008).

Tabela 2 - Estágios do processamento de imagem digital.

Processo	Nível de visão
Captura/Aquisição	
Pré-processamento	Baixo
Segmentação	
Descrição	Médio
Reconhecimento	
Interpretação	Alto

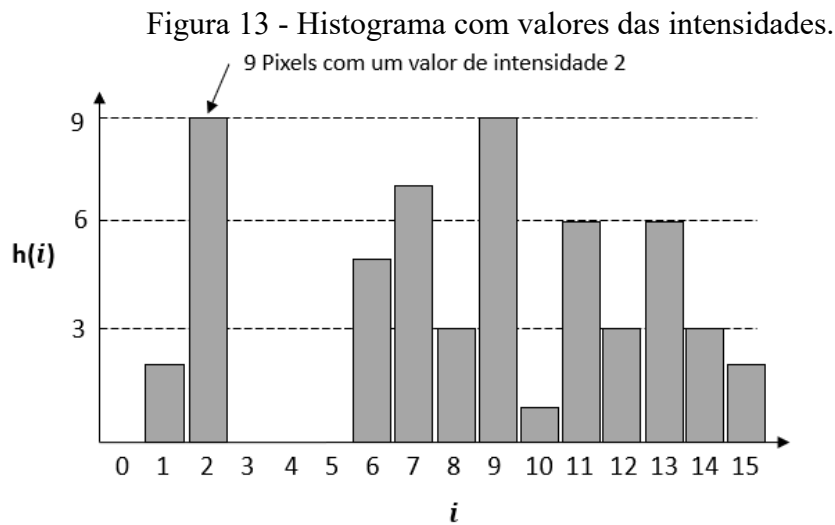
Fonte: GARCÍA SANTILLÁN (2008).

3.4.1.2.2 Pré-processamento

É um processo que consiste na obtenção de uma imagem digital, dependendo da aplicação realizam-se as seguintes técnicas: atenuação do ruído presente na imagem, realce do contraste ou de determinados detalhes da imagem (RODRIGUEZ MORALES & SOSSA AZUELA, 2011).

3.4.1.2.3 Histograma

Em imagens digitais, um histograma representa o número de pixels que possuem cores em cada uma das listas de faixas de cores fixas, que estão espalhadas pelo espaço de cores da imagem. O modelo de cores mais simples são as imagens em escala de cinza (Cuevas et al., 2010). A Figura 13 mostra um histograma que descreve diferentes tons de níveis de cinza, com um nível máximo de $i = 15$, a barra no nível 2 indica que existem 9 pixels naquele nível, ou seja, eles são repetidos 9 vezes naquele valor.



Fonte: Rodriguez Morales & Sossa Azuela (2011)

3.4.1.2.4 Segmentação

É um processo de nível médio de visão artificial que consiste em separar uma imagem digital em regiões de interesse das demais não importantes, no que diz respeito a uma ou mais características, por exemplo: brilho, cor, tamanho, comprimento e forma (RODRIGUEZ MORALES & SOSSA AZUELA, 2011). Este processo é fundamental no processamento porque informações corretas ou incorretas são obtidas da imagem processada.

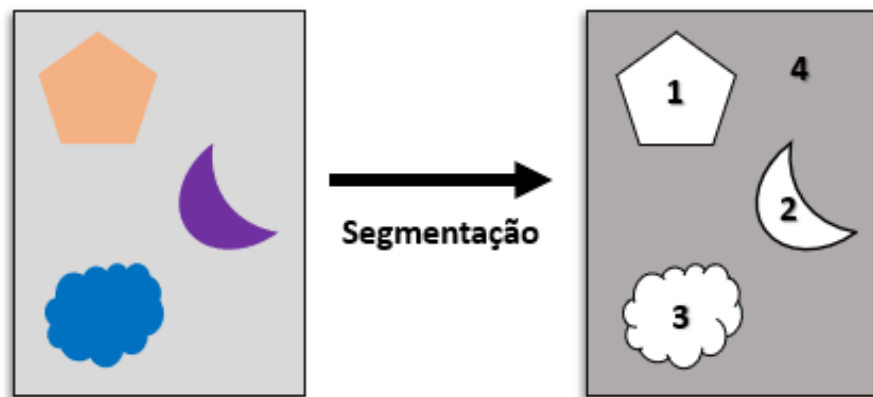
Existem vários tipos de segmentação como, por exemplo, segmentação binária ou também chamada de *thresholding* ou limiarização, que distingue apenas duas categorias, sendo aquelas que não são binárias como segmentação múltipla; segmentação semiautomática, na qual, por meio de anotações prévias, são analisadas regiões específicas; segmentação semântica, que é responsável por distinguir objetos específicos; segmentação instanciada que é responsável pelo reconhecimento de indivíduos; e segmentação panóptica, que combina segmentação semântica e instantânea.

O processo de limiarização é um tipo de segmentação que consiste no pressuposto de que os objetos são constituídos por pixels de intensidade homogênea, cada pixel é comparado com um limite predefinido, este valor separa a imagem em duas categorias em nível de cinza e depende do valor do limite para obter uma qualidade de segmentação (CUEVAS et al., 2010).

Exemplos de segmentação são: localizar os olhos de uma pessoa ao focar com uma câmera, separar os caracteres de um texto em uma imagem, localizar as placas dos veículos, detectar doenças ou patologias a partir de imagens de vegetais (GARCÍA SANTILLÁN, 2008).

Na Figura 14 observa-se a representação do processo de segmentação de uma imagem simples, aprecia-se que antes de entrar no processo de segmentação existe uma imagem digital sem tratamento com diferentes níveis de intensidade de luz, mas após a segmentação obtém-se uma informação de existência objetos.

Figura 14 - Esquema que representa o processo de segmentação.



Fonte: O autor.

3.4.1.2.5 Caracterização de objetos binários

Uma forma de descrever uma imagem binária é por meio de características como perímetro, área e número de objetos, que podem ser facilmente calculados pelo computador, com o qual a imagem ou um segmento dela pode ser manipulado, para então utilizar técnicas de reconhecimento de padrões (CHANCO GAMONAL, 2020).

Características geométricas: um objeto O em uma imagem binária é moldado por meio de uma distribuição de pontos de valor $X_i = (x, y)$ em uma grade bidimensional. Para o cálculo das características geométricas, um objeto é um conjunto de valores agrupados sob um critério de vizinhança (CUEVAS et al., 2010).

De acordo com CUEVAS et al., (2010) define uma imagem binária como:

$$O = \{X_1, X_2, \dots, X_N\} = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_N, Y_N)\} \quad (2)$$

Um objeto pode ser caracterizado de acordo com seu perímetro, diâmetro, área ou a caixa mínima em que o objeto pode estar contido (caixa delimitadora). O perímetro de um objeto O é determinado com base no comprimento de seu contorno externo, a Eq. (3) é considerada para calcular o perímetro, pois é necessário conhecer o tipo de vizinhança, ficar claro que a distância de uma vizinhança de 8 é menor do que uma vizinhança de 4, levando em conta que a vizinhança é o objeto que já foi localizado no processo de segmentação (CHANCO GAMONAL, 2020).

De acordo com CUEVAS et al., (2010) define o perímetro em uma expressão:

$$\text{Perímetro}(O) = \sum_{i=1}^M \text{comprimento}(C_i) \quad (3)$$

Em que

$$\text{Comprimento}(C_i) = f(x) = \begin{cases} 1 & \text{para } y_c = 0,2,4,6 \\ \sqrt{2} & \text{para } y_c = 1,3,5,7 \end{cases} \quad (4)$$

O perímetro calculado pelas Eqs. (3) e (4) é um valor que determina as distâncias reais, para as quais na prática este valor é ajustado. De acordo com CUEVAS et al., (2010) define o novo valor do perímetro na seguinte expressão matemática:

$$U(O) = 0.95 * \text{Perímetro}(O) \quad (5)$$

O diâmetro, segundo GARCÍA SANTILLÁN, (2008), é expresso com a seguinte expressão matemática:

$$\text{Diam} = \max_{i,j} [D(p_i, p_j)] \quad (6)$$

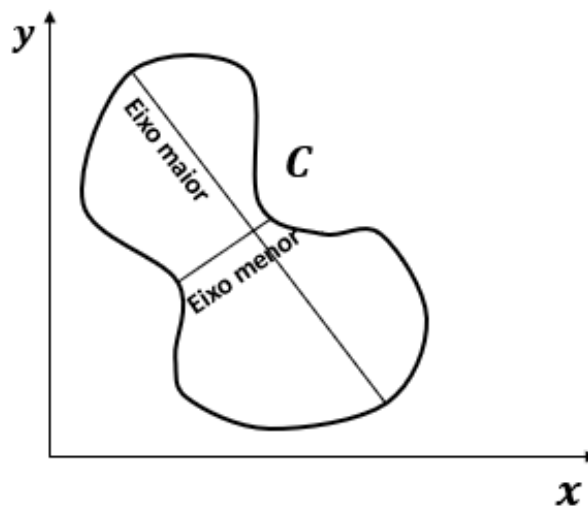
Em que:

D = é a medida da distância entre os pontos p_i e p_j , que são os pontos extremos do contorno.

A Figura 15 mostra um exemplo para encontrar o diâmetro de uma imagem, consistindo em que a linha que une as duas extremidades é considerada o eixo maior e a linha que passa pelo centro do eixo maior, mas perpendicularmente é considerada o eixo menor.

A área de um objeto O é calculada pelo número de pixels. De acordo com CUEVAS et al., (2010) define a área como:

Figura 15 - Eixo menor e maior do contorno C.



Fonte: RODRIGUEZ MORALES & SOSSA AZUELA (2011).

$$\text{Área}(O) = N = |O| \quad (7)$$

Onde, N é o número de pixels do objeto.

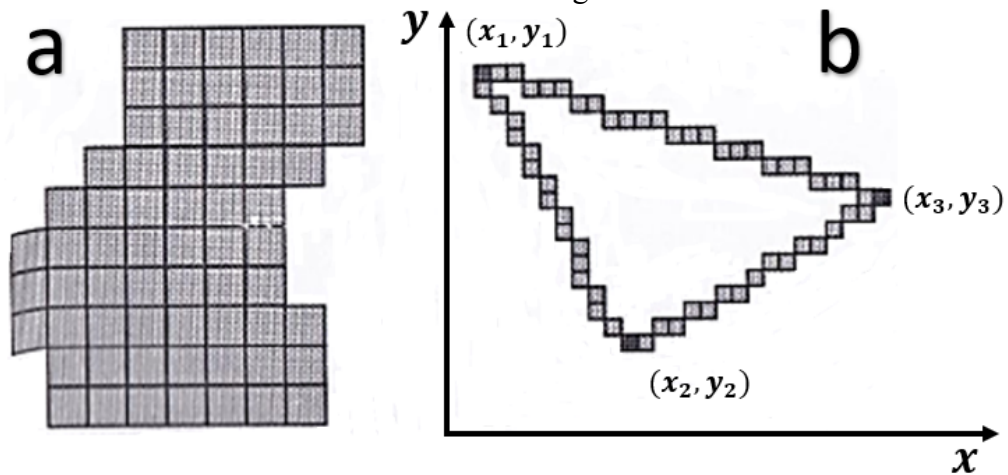
Se um objeto é composto por uma área que não contém pixels agrupados, mas sim um contorno que o rodeia, é feita uma aproximação da área do contorno externo fechado (CHANCO GAMONAL, 2020).

De acordo com CUEVAS et al., (2010) aplica-se a seguinte Equação:

$$\text{Área}(O) = \frac{1}{2} * \left| \sum_{i=1}^M (x_i y_{[(i+1) \bmod M]} - x_{[(i+1) \bmod M]} * y_i) \right| \quad (8)$$

A Figura 16a mostra o exemplo básico de área medida em pixels incluindo seu contorno de 67 pixels e a Figura 16b mostra uma área com contorno interno.

Figura 16 - Aplicação de área em imagens: (a) área de uma imagem simples (b) uma figura em forma de triângulo.



Fonte: editado de RODRIGUEZ MORALES & SOSSA AZUELA (2011).

O *bounding box* ou caixa delimitadora é a forma quadrada mínima que o objeto contém; este retângulo está localizado por coordenadas nos eixos "x" e "y" (CHANCO GAMONAL, 2020). Según CUEVAS et al., (2010) define dos puntos para o *bounding box*:

$$BB(O) = (x_{min}, x_{max}, y_{min}, y_{max}) \quad (9)$$

Onde x_{min} e y_{min} são as coordenadas mínimas do eixo x e y, e x_{max} e y_{max} são as coordenadas máximas do eixo x e y.

3.4.1.2.6 Reconhecimento

É um processo de nível de visão médio, que consiste em identificar os objetos à categoria correspondente, prevendo-se que cada objeto pertença a uma categoria ou classe (García Santillán, 2008).

3.4.1.2.7 Interpretação

É um processo de alto nível de visão, que consiste em classificar um conjunto de objetos previamente reconhecidos (chaves, parafusos, ferramentas, etc.) em que os objetos em uma imagem devem ser percebidos de forma simples (GARCÍA SANTILLÁN, 2008).

3.5 AI E VISÃO ARTIFICIAL NA ANÁLISE E RASTREABILIDADE DE VERDURAS

A qualidade de uma peça de fruta ou legume, fresca ou processada, é definida por uma série de características que a tornam relativamente atrativa para os consumidores, tais como maturidade, tamanho, peso, forma, cor, presença de sujidade e doenças, presença ou ausência de caule, presença de sementes, teor de açúcar, etc. Essas características englobam todos os fatores que influenciam a aparência de um produto e podem incluir qualidades nutricionais e sensoriais ou propriedades relacionadas à sua conservação (SALDAÑA et al., 2013). Atualmente, grande parte dessas características é frequentemente analisada por meio de inteligência artificial e visão artificial por meio de imagens, que são pré-processadas, segmentadas e interpretadas de acordo com parâmetros de qualidade pré-estabelecidos, criando processos cada vez mais eficazes (SALDAÑA et al., 2013). A caracterização com IA e visão artificial com base em características dimensionais e colorimétricas tem permitido realizar registros de forma automatizada e mais otimizada, conseguindo armazenar de forma mais eficiente, quando, onde e que tipo de características anómalas ou fora dos padrões de qualidade tem sido detectados permitindo assim um processo de rastreabilidade que permite resolver problemas de forma mais rápida, em comparação com o trabalho manual que é comumente feito hoje (KONDO, 2010).

4 MATERIAL E MÉTODOS

4.1 COLETA DE AMOSTRA

Mamões comerciais (*Carica papaya* L.) cv. ‘Golden’ foram adquiridos no mercado local de Florianópolis, SC, Brasil. As frutas foram selecionadas de acordo com o grau de maturação (Figura 17). Um total de 16 mamões foram adquiridos em estado de maturação verde. Cada um deles foi analisado nos dias 0, 3, 5 e 7 a partir do momento da aquisição e foram tiradas fotos da frente e do verso de cada mamão, obtendo assim um total de 218 imagens extraídas, observando cada uma como uma amostra individual independente do tempo.

Figura 17 - Mamões em diferentes estágios de maturação: (a) imaturos, (b) semi-maduros, (c) maduros.



Fonte: O autor.

4.2 CLASSIFICAÇÃO DE MAMÃO USANDO TRIAGEM MANUAL

Os mamões foram classificados visualmente de acordo com o estágio de maturação, de acordo com a metodologia utilizada por BEHERA et al., (2021). As frutas foram classificadas em verdes (pele verde sem listra amarela), semi-maduros (pele verde com listra amarela bem definida) e maduros (pele claramente de cor amarela e pode ou não ter pequenas áreas verdes claras) de acordo com a cor da pele. Esta classificação manual foi realizada para fazer uma comparação com a classificação obtida com a linguagem de programação por visão computacional. Paralelamente, o volume do mamão foi determinado pelo método de deslocamento de água (V_r) com base no princípio de Arquimedes (MOHAZZAB, 2017). Para

determinar o volume, foi registrado o nível de água em um recipiente antes e depois da imersão da fruta. O volume das frutas foi determinado de acordo com a Eq. (10):

$$\text{Volume da fruta} = v_f - v_i \quad (10)$$


Onde, v_f e v_i são o volume final e inicial (mL) do recipiente, respectivamente.

A massa das frutas foi calculada pesando cada mamão em uma balança analítica (KNCD 60/1, KN Waagen Balance Ltda). Além disso, as dimensões de altura e largura de cada mamão foram registradas por meio de uma fita métrica.

4.3 AQUISIÇÃO E PROCESSAMENTO DE IMAGENS

Para a aquisição das imagens, os mamões foram colocados dentro de uma câmera com iluminação homogênea de uma fonte de lâmpada fluorescente difusa. Um fundo branco foi incorporado para melhorar o contraste e uma régua foi colocada neste fundo para permitir a calibração no código desenvolvido (Figura 18). As imagens foram adquiridas usando uma câmera digital de alta resolução (Nikon AF-S DX Nikkor 18-55 mm 1: 3,5–5,6G VR II, 0,28 m / 0,92 ft ø 52), sem flash e zoom (55 ×) (VIEIRA et al., 2020).

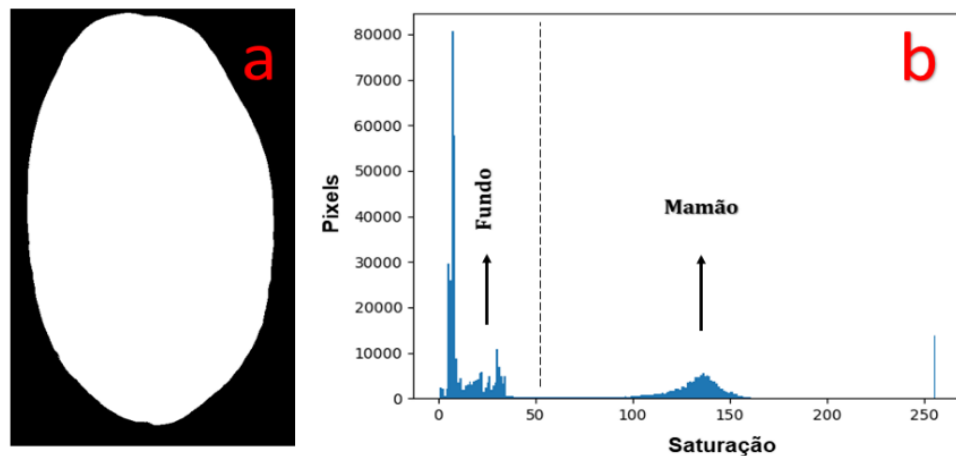
Figura 18 - Desenho experimental para captura de imagens, composto por câmera (a), fonte de luz (b), fruta a ser analisada (c), fundo com menos saturação que fruta (d), régua de calibração (e) e uma caixa que isola a luz externa (f).



Fonte: O autor.

A análise das imagens foi realizada no software Visual Studio Code com a linguagem de programação *Python* na plataforma *Windows*. Foram utilizados os pacotes de código OpenCV (para leitura e processamento de imagens) e Numpy (para operar com imagens a partir de matrizes). Nesta linguagem de programação foram lidas imagens no formato RGB por padrão. Para separar o mamão do fundo, o ruído foi primeiro removido aplicando um desfoque à imagem original e depois convertido do formato RGB para HSV. A Eq. (11) foi usado em *Python* para alterar o formato da imagem. A mudança do formato RGB para HSV facilitou o mascaramento para filtrar a imagem. Nesse caso, o filtro de imagem foi realizado no canal de saturação (S), a partir do qual foi realizada a limiarização, para separar a fruta do fundo (Figura 19a). Para uma melhor compreensão do processo de segmentação pelo limiar, foram analisados histogramas (Figura 19b). Os histogramas baseados no canal S exibiram picos que representam as regiões com mais e menos saturação. Devido à saturação desigual pelo contraste entre o fundo e a fruta, há uma divisão perceptível entre os picos no histograma, que correspondem à região do fundo e do mamão.

Figura 19 - Extração de fundo com limiar representado na imagem (a) e histograma (b).



Fonte: O autor.

$$\begin{aligned}
V &\leftarrow \max(R, G, B), \\
S &\leftarrow \begin{cases} \frac{V - \min(R, G, B)}{V} & \text{se } V \neq 0 \\ 0 & \text{caso contrário} \end{cases}, \\
H &\leftarrow \begin{cases} 60(G - B)/(V - \min(R, G, B)) & \text{se } V = R \\ 120 + 60(B - R)/(V - \min(R, G, B)) & \text{se } V = G \\ 250 + 60(R - G)/(V - \min(R, G, B)) & \text{se } V = B \\ 0 & \text{se } R = G = B \end{cases}
\end{aligned} \tag{11}$$

4.4 EXTRAÇÃO DE RECURSOS DE COR DAS IMAGENS

A cor da pele do mamão foi analisada para classificação de acordo com o seu estágio de maturação. Foi utilizado o método proposto por PANDEY et al., (2014) onde as imagens foram convertidas de RGB para o sistema de cores CIELab, analisando a região que foi extraída usando o espaço de cores HSV. Este modelo de cores com canais L^* , a^* e b^* é frequentemente utilizado para caracterizar cores na indústria de alimentos, pois tem mostrado maior versatilidade do que o modelo RGB para reconhecimento e segmentação de cores (LEÓN et al., 2006). Na escala CIELab, L^* está associado ao índice de luminosidade, a^* está relacionado às tonalidades de cor de vermelho (+) a verde (-) e b^* está correlacionado às tonalidades de cor de amarelo (+) a azul (-) (Vieira et al., 2020). De RGB para CIELab a conversão do modelo é não linear, portanto, o espaço de cores RGB foi transformado em um espaço de cores intermediário, ou seja, sRGB ou CIEXYZ. Essa conversão torna os dados independentes do dispositivo. A conversão não linear foi realizada usando as Eqs. 12 e 13:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.607 & 0.174 & 0.200 \\ 0.299 & 0.589 & 0.114 \\ 0.00 & 0.066 & 1.116 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{12}$$

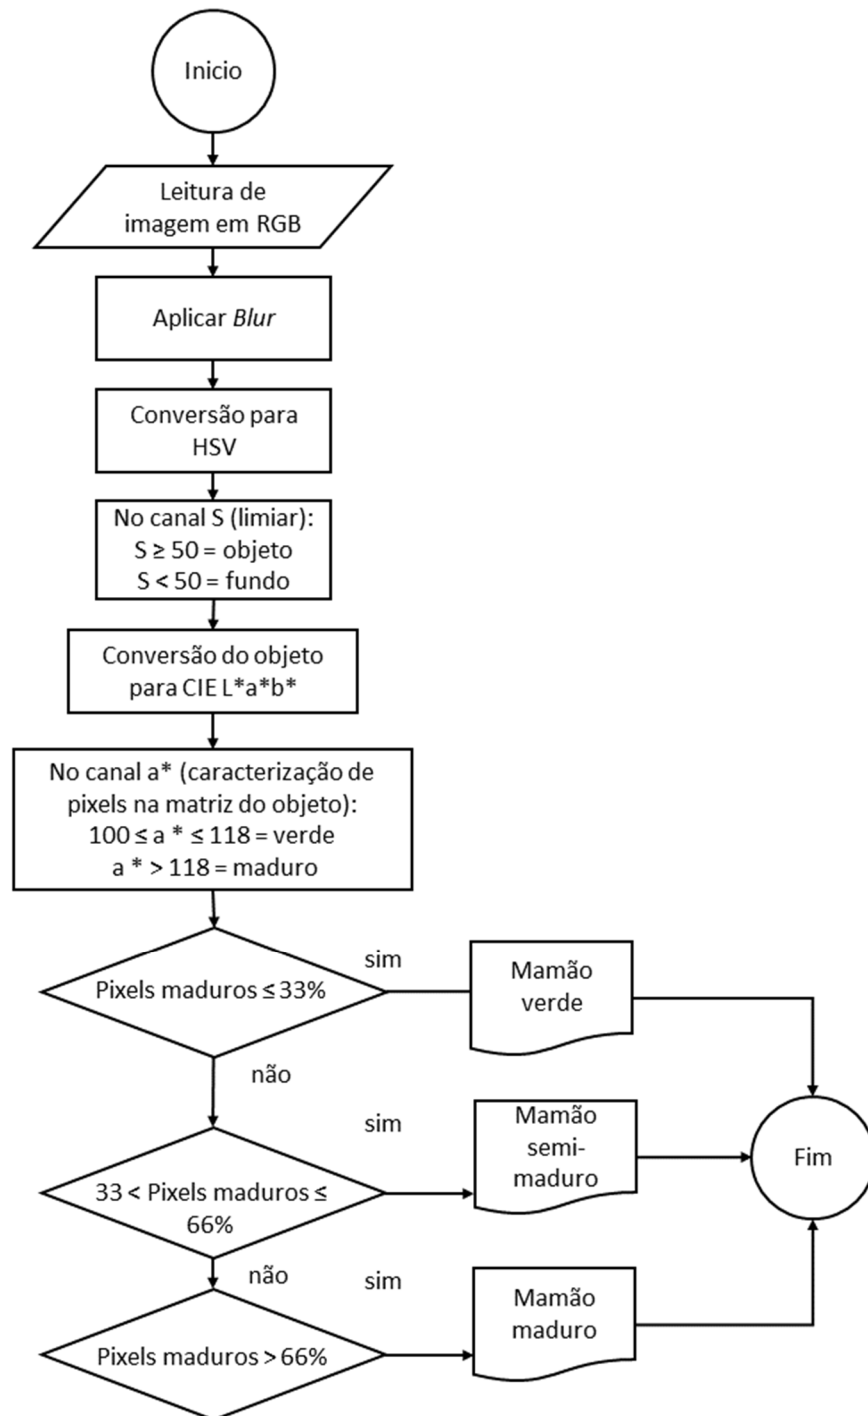
$$\begin{aligned}
L^* &= 116 \left(\sqrt[3]{\frac{Y}{Y_0}} \right) - 16, \\
a^* &= 500 \left[\sqrt[3]{\frac{X}{X_0}} - \sqrt[3]{\frac{Y}{Y_0}} \right], \\
b^* &= 200 \left[\sqrt[3]{\frac{Y}{Y_0}} - \sqrt[3]{\frac{Z}{Z_0}} \right]
\end{aligned} \tag{13}$$

Onde $\frac{Y}{Y_0} > 0.01$, $\frac{X}{X_0} > 0.01$ and $\frac{Z}{Z_0} > 0.01$. (X_0, Y_0, Z_0) mostra os valores X, Y, Z para o branco padrão.

4.5 CLASSIFICAÇÃO DO MAMÃO DE ACORDO COM O ESTÁGIO DE MATURAÇÃO

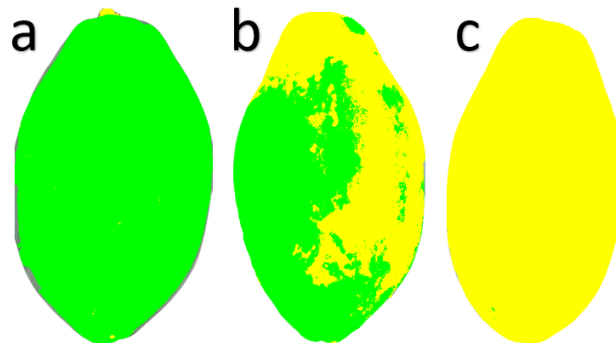
O estágio de maturação dos mamões foi investigado usando o mesmo modelo de cores L^* , a^* e b^* , onde o canal a^* foi usado para determinar o estágio de maturação. A Figura 20 representa o pseudocódigo para a classificação do mamão de acordo com seu estado de maturação. Particularmente, na linguagem de programação *Python*, os valores do canal a^* variam de 0 a 256, o que corresponde às cores verde a vermelho. A classificação da maturação do mamão foi implementada com um limite estabelecido de acordo com o valor da cor no canal a^* . Cada pixel da imagem analisada tinha certas condições para ser considerado um pixel não maduro ou maduro, que foram estabelecidas por tentativa e erro para o melhor resultado possível: verde $100 \leq a^* \leq 118$ e maduro $a^* > 118$ (PANDEY et al., 2014). Posteriormente, os mamões foram classificados como verdes, semi-maduros e maduros, com base na porcentagem de pixels maduros e não maduros: verdes $\leq 33\%$ dos pixels maduros (Figura 21a), semi-maduros $33\% < \text{pixels maduros} \leq 66\%$ (Figura 21b), e maduros $> 66\%$ pixels maduros (Figura 21c).

Figura 20 - Pseudocódigo de caracterização do mamão de acordo com seu estado de maturação.



Fonte: O autor.

Figura 21 - Interpretação de imagens de acordo com as condições especificadas: (a) mamão imaturo, (b) mamão semi-maduro, (c) mamão maduro.



Fonte: O autor.

4.6 ESTIMATIVA DE VOLUME E MASSA USANDO ANÁLISE DE IMAGEM


Para a estimativa do volume e da massa, foi assumido que o mamão tem a forma eixo-simétrica, portanto, o volume das seções transversais tem a mesma geometria (HUYNH et al., 2020). Em cada seção (Figura 22), Eq. (14) foi utilizado para calcular o volume do mamão de acordo com um cone cortado.

$$V_i = \frac{h_1\pi}{3}(r_1^2 + r_2^2 + r_1 * r_2) \quad (14)$$

Onde V_i é o volume de cada cone cortado (cm^3), r_1 e r_2 são o raio (cm) das áreas inferior e superior, respectivamente e h_1 é a altura (cm).

Na presente pesquisa, considerou-se que a seção transversal do mamão é um círculo, portanto, as áreas B_1 e B_2 observadas na Figura 22a, podem ser calculadas usando a Equação 15 e 16 para o cálculo da área inferior e seção transversal superior, respectivamente.

Figura 22 - Configuração geométrica para seção transversal (a) e seção superior e inferior do mamão (b).



Fonte: O autor.

$$B_1 = \pi r_1^2 \quad (15)$$

$$B_2 = \pi r_2^2 \quad (16)$$

O topo e a base de cada mamão foram considerados um cone elíptico (Figura 22b). Portanto, o volume da parte superior e inferior desta fruta foi estimado usando a fórmula do cone elíptico de acordo com a Eq. (17):

$$V_{top/base} = \frac{\pi 2d h_2}{6} \quad (17)$$

Onde, d é o diâmetro (cm) da base do cone e h_2 é sua altura (cm).

O volume total do mamão foi calculado como a soma dos volumes do cone cortado mais os dois volumes do cone elíptico das regiões inferior e superior (Eq. 18).

$$V_e = \left(\sum V_i \right) + V_{top} + V_{base} \quad (18)$$

Na sequência, a densidade média ($\bar{\rho}$) e individual (ρ_i) foram calculadas usando a massa calculada para a densidade média ($M_{\bar{\rho}}$) e densidade individual (M_{ρ_i}), respectivamente, usando as Eqs. 19 - 22:

$$\bar{\rho} = \frac{\sum_{i=1}^n \rho_i}{n} \quad (19)$$

$$\rho_i = \frac{M_r}{V_e} \quad (20)$$

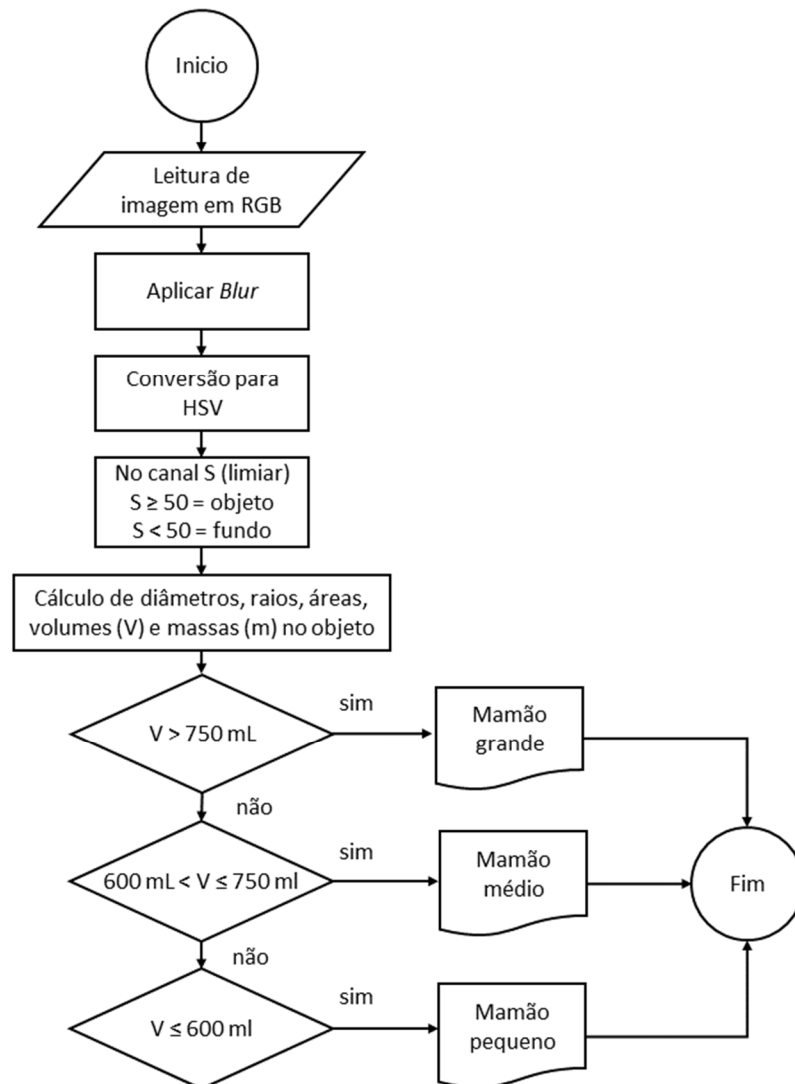
$$M_{\bar{\rho}} = V_e \bar{\rho} \quad (21)$$

$$M_{\rho_i} = V_e \rho_i \quad (22)$$

Onde n é o número de amostras e M_r é a massa obtida na balança analítica.

O pseudocódigo para representar a estimativa e classificação com base no volume é mostrado na Figura 23.

Figura 23 - Pseudocódigo de caracterização do mamão baseado no volume e massa.



Fonte: O autor.

4.7 ANÁLISE ESTATÍSTICA

Para histogramas em função de volume e massa, a fórmula de Sturges (Eq. 23) foi usada para definir o número de classes (K) com base no número de pontos de dados (n). O teste de Kolmogorov-Smirnov foi utilizado para determinar a normalidade do conjunto de valores obtidos pelas técnicas tradicionais e os obtidos por estimativa. Para os conjuntos de valores que apresentam distribuição normal, foi aplicado o teste t-Student para verificar se os valores medidos com as técnicas tradicionais e os estimados computacionalmente são estatisticamente diferentes. O teste de Wilcoxon foi usado para estudar a similaridade de conjuntos de dados que não apresentam normalidade. Em todos os testes estatísticos, o nível de confiança foi de 95%. O tratamento dos dados foi realizado nos softwares Microsoft Excel® (2016) e IBM SPSS Statistics 26.0.

$$K = 1 + 3.3 \text{Log}(n) \quad (23)$$

5 RESULTADOS E DISCUSSÃO

5.1 CLASSIFICAÇÃO DO MAMÃO DE ACORDO COM O ESTÁGIO DE MATURAÇÃO

Em relação aos resultados em função da cor, a mudança nos valores dos pixels no canal a* descreve o estágio de maturação do mamão. O código desenvolvido por visão computacional alcançou alta precisão para classificar o mamão com base na cor da pele, e o número total de amostras classificadas corretamente foi de 95,0% (Tabela 3). A eficácia da classificação do mamão depende dos intervalos que são estabelecidos no canal a* para definir se um pixel está maduro ou não, também depende da porcentagem de pixels que são designados para definir o estágio de maturação do mamão. Desta forma, os parâmetros estabelecidos mostraram-se adequados para classificação dos mamões de acordo com os valores obtidos no canal a*. PANDEY et al., (2014) classificaram mangas maduras e verdes com visão artificial usando MATLAB na plataforma Windows e concluíram que este código computacional pode classificar essas frutas com alta precisão geral (98,9%). Resultados semelhantes foram obtidos BEHERA et al., (2021) que classificou o mamão por meio do software de programação MATLAB (precisão geral de 100%). Porém, neste estudo, o código desenvolvido foi utilizado apenas para classificar os mamões de acordo com a cor da pele.

Tabela 3 - Matriz de confusão relacionada à classificação da maturação do mamão.

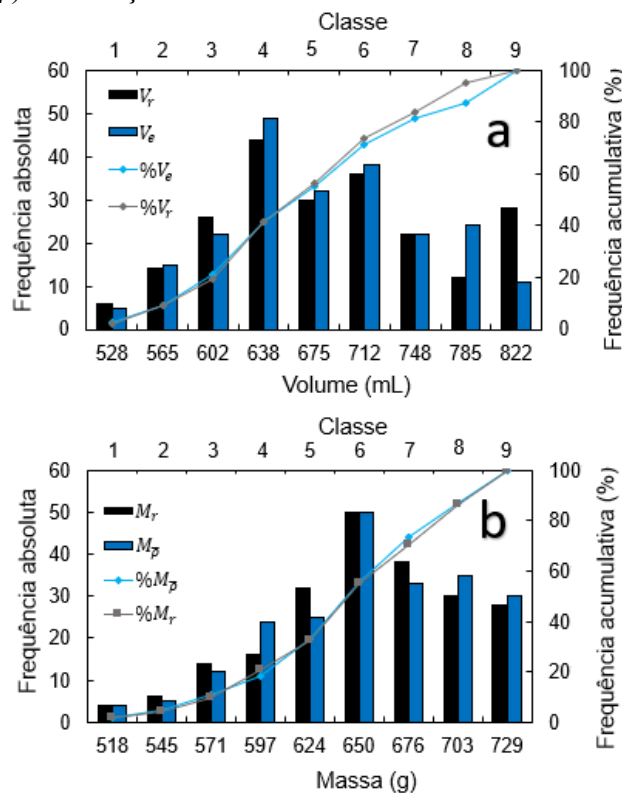
Estágio real	Estágio de maturação estimado computacionalmente			Total	Correto (%)
	Imaturo	Semi-maduro	Maduro		
	Imaturo	138	0		
Semi-maduro	2	34	4	40	85
Maduro	0	0	40	40	100
Total	140	34	44	218	95

Fonte: O autor.

5.2 ESTIMATIVA DE VOLUME E MASSA

Os histogramas obtidos mostraram distribuição multimodal para volume e distribuição unimodal para massa (Figura 24). Histogramas de volume real (V_r) calculado experimentalmente em relação ao volume estimado (V_e) calculado computacionalmente (Figura 24a), e a massa real (M_r) calculada experimentalmente em relação à massa estimada usando a densidade média ($M_{\bar{\rho}}$) calculada computacionalmente (Figura 24b) revelaram que os valores experimentais foram comparáveis aos obtidos experimentalmente, exceto para o volume nas classes 8 e 9 (Figura 24a), e para a massa na classe 5 (Figura 24b).

Figura 24 - Histogramas de: (a) volume real (V_r) em relação ao volume estimado (V_e) e (b) massa real (M_r) em relação à massa estimada usando a densidade média ($M_{\bar{\rho}}$).



Fonte: O autor.

Os valores do volume estimado (V_e) calculado computacionalmente foram muito próximos ao encontrado para o volume real (V_r) calculado experimentalmente. Nesse caso, o erro experimental (ε_x) e o desvio padrão (σ_{ε_x}) foram baixos, sugerindo que a visão artificial poderia ser utilizada para estimar o volume de mamões com diferentes estágios de maturação

(Tabela 4). Em relação aos valores de massa, foram calculados a partir da densidade média ($M_{\bar{\rho}}$), densidade individual ($M_{\rho i}$). Observou-se que o $M_{\bar{\rho}}$ apresentou os maiores valores de ε_x e $\sigma_{\varepsilon x}$ quando comparado aos demais valores estimados aos valores de $M_{\rho i}$. Este resultado pode ser devido à oscilação nos valores de densidade observados neste estudo (0,807 - 1,073 g/mL), apresentando um desvio padrão de 0,059 g/mL. Desta forma, uma grande variação nos valores de densidade poderia impactar negativamente na estimativa dos valores de massa usando a densidade média da fruta. $M_{\rho i}$ é complexo de estimar, uma tendo em conta que a densidade individual de cada fruta deve ser conhecida. Comparando com os dados da literatura, os ε_x foram comparáveis aos informados por HUYNH et al., (2020) para cenouras ($\varepsilon_x = 3,4\%$) e pepinos ($\varepsilon_x = 8,3\%$), e inferior ao estimado por BOZOKALFA & KILIC, (2010) para pimentas ($\varepsilon_x = 15,6\%$), ambos classificando os alimentos de acordo com seu volume.

Tabela 4 - Estatística descritiva do volume e massa reais e estimados em mamão.

Parâmetro	Média	σ	Min.	Max.	ε_x	$\sigma_{\varepsilon x}$
V_r (mL)	685,9	79,4	510,0	840,0		
V_e (mL)	686,9	76,6	500,9	867,0	1,6	1,2
M_r (g)	655,5	52,2	505,0	742,0		
$M_{\bar{\rho}}$ (g)	659,4	73,5	480,9	832,4	5,2	4,3
$M_{\rho i}$ (g)	656,9	53,5	496,0	758,7	1,6	1,2

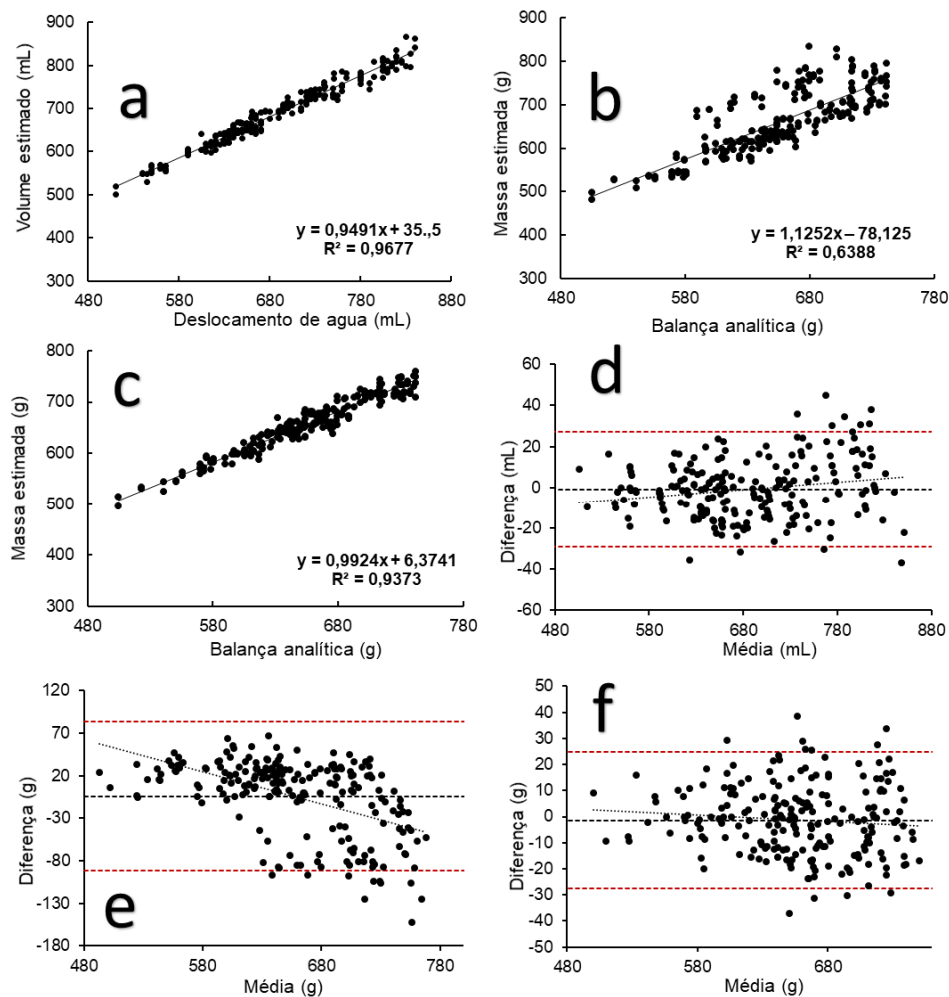
V_r : volume real calculado experimentalmente (mL), V_e : volume estimado (mL), M_r : massa real calculada experimentalmente (g), $M_{\bar{\rho}}$: massa calculada usando a densidade média (g), $M_{\rho i}$: massa calculada usando a densidade individual (g), σ : desvio padrão, ε_x : erro experimental, $\sigma_{\varepsilon x}$: desvio padrão do erro experimental.

Fonte: O autor.

Nos gráficos de dispersão de V_r versus V_e tiveram uma correlação linear com coeficiente de correlação de 0,97, confirmando a similaridade entre os valores reais e estimados (Figura 25a). Por outro lado, os diagramas de dispersão de M_r versus $M_{\bar{\rho}}$ apresentaram baixo valor de coeficiente, mostrando que não é viável prever a massa com base na densidade média (Figura 25b), demonstrando que não é aconselhável estimar a massa em função da densidade média, pois apresenta um coeficiente de correlação não tão confiável de 0,78. De maneira geral, observou-se que o percentual de erro aumentou com o aumento do volume e da massa da fruta, indicando que os dados se tornam mais imprevisíveis. Altos valores de coeficiente de correlação são desejados para prever os parâmetros da fruta. Dessa forma, IBRAHIM et al. (2016) E

NYALALA et al. (2019) obtiveram valores de coeficiente de correlação de 0,99 e 0,92 em mangas e tomates classificados de acordo com seu volume por visão computacional.

Figura 25 - Gráficos de dispersão de: (a) volume real (V_r) versus volume estimado (V_e); (b) massa real (M_r) versus massa estimada usando a densidade média ($M_{\bar{\rho}}$); (c) massa real (M_r) versus massa estimada usando a densidade individual (M_{ρ_i}). Bland-Altman representa: (d) a diferença de V_e e V_r (e) $M_{\bar{\rho}}$ e M_r (f) e M_{ρ_i} e M_r .



Fonte: O autor.

Os gráficos de Bland-Altman foram representados com o intuito de compreender a precisão dos valores estimados do mamão. As Figuras 25d-f foram feitas com a metodologia descrita por Bland-Altman (BLAND & ALTMAN, 1999). Ao comparar o desvio de V_e e V_r (Figura 25d), observou-se que as diferenças estiveram em torno de 27,2 mL e -29,2 mL, representando um erro aceitável de 4% e 4,2%, respectivamente. Além disso, a maioria dos valores estimados está dentro dos limites com intervalo de confiança de 95%. Os desvios entre

$M_{\bar{p}}$ e M_r mostraram diferenças em torno de 83,8 g e -91,7 g, estando associados a valores de erro toleráveis de 12,7% e 14%, respectivamente (Figura 25e). Nesse caso, existe uma linha de tendência significativa ($p < 0,05$), indicando que a diferença é função da massa. Finalmente, o gráfico de Bland-Altman dos valores de $M_{\rho i}$ e M_r (Figura 25f) permite observar que as diferenças dos limites superior (25,0 g) e inferior (-27,7 g) são menores do que aqueles observados na Fig. 5e, confirmando a alta precisão uma vez que os valores são próximos aos obtidos experimentalmente. O método de corte do cone aplicado por HUYNH et al., (2020) foi utilizado para estimar o volume de cenouras e pepinos, sendo que as diferenças variaram entre 15 mL e -15 mL. Em outra pesquisa, OMID et al., (2010) obtiveram diferenças de volume entre 1,7 mL e -1,6 mL, 8 mL e -7 mL, 7 mL e -6 mL, e 6 mL e -5 mL para lima, limão, laranja e tangerina, respectivamente, usando o somatório dos segmentos para estimar o volume da fruta.

De acordo com o teste de Kolmogorov-Smirnov, o M_r apresenta normalidade nos dados ($p < 0,05$) e os parâmetros V_r , V_e , $M_{\bar{p}}$, e $M_{\rho i}$, não apresentam normalidade ($p > 0,05$), portanto, é aconselhável realizar o teste de similaridade para dois grupos de dados com o teste de Wilcoxon. Os dados obtidos pelo teste de Wilcoxon mostraram $p > 0,05$ para os dados V_r e V_e , indicando que esses valores são significativamente semelhantes. Embora a relação de dados entre M_r e $M_{\bar{p}}$ apresente um desvio com baixa confiabilidade, o teste de Wilcoxon mostrou que os dados não diferiram estatisticamente ($p > 0,05$). Da mesma forma, M_r e $M_{\rho i}$ apresentaram similaridade significativa ($p > 0,05$). Assim, o código desenvolvido poderia ser testado para verificar se pode ser utilizado para classificar ou analisar o mamão com base na massa estimada com a densidade média.

No presente estudo, o potencial do código computacional desenvolvido para classificar o mamão com base no volume e na massa foi validado por meio de uma matriz de confusão (Tabela 5). A classificação por tamanho apresentou um percentual de precisão geral para V_r de 90,5%, mostrando que essa classificação poderia ser utilizada em escala industrial. A classificação do mamão pelo $M_{\bar{p}}$ teve uma acurácia de 77,9%, que aumentou até 88,1% quando foram utilizados os valores de $M_{\rho i}$. Esses valores de acurácia são aceitáveis, sugerindo que o código desenvolvido também poderia ser utilizado para classificar o mamão de acordo com sua massa. Anteriormente, DE LUNA et al., (2019), utilizando limiarização, classificou o tomate nos tamanhos pequeno, médio e grande, da área, perímetro e rádio, com precisão geral de 85,8%, 65,8% e 80,0%, respectivamente.

Tabela 5 - Matriz de confusão para classificação do tamanho do mamão com base em volume e massa.

Tamanho	Tamanho estimado			Total	C (%)	Tamanho estimado			Total	C (%)	Tamanho estimado			Total	C (%)
	(unidades)* V_e					(unidades)* $M_{\bar{\rho}}$					(unidades)* M_{ρ_i}				
	S	M	L			S	M	L			S	M	L		
S	53	4	0	57	93,0	28	3	1	32	87,5	28	3	0	31	90,3
M	6	104	0	110	94,5	18	70	26	114	61,4	5	100	9	114	87,7
L	0	8	43	51	84,0	0	11	61	72	84,7	0	10	63	73	86,1
Total	59	116	43	218	90,5	46	84	88	218	77,9	33	113	72	218	88,1

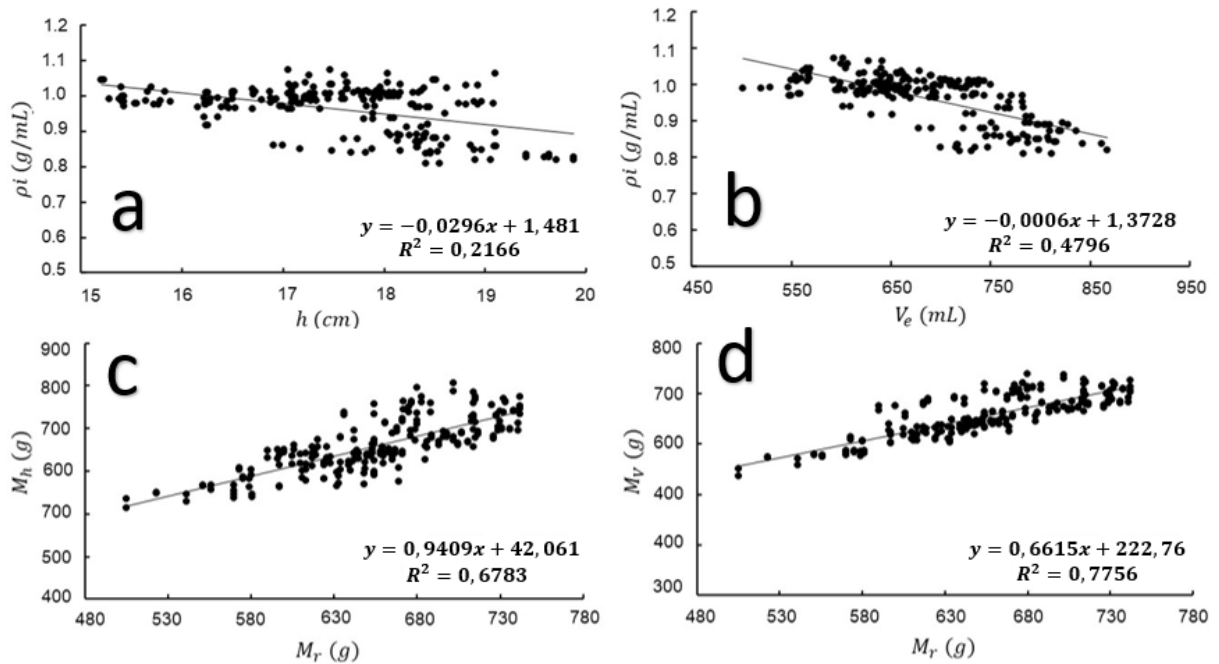
*Os valores foram obtidos usando valores experimentais. V_e : volume estimado, $M_{\bar{\rho}}$: massa calculada usando a densidade média, M_{ρ_i} : massa calculada usando a densidade individual, C (%): porcentagem da estimativa correta.

Classificação dos mamões por tamanho com base no volume: pequeno (S) ≤ 600 mL; 600 mL <meio (M) ≤ 750 mL; grande (L) > 750 mL.

Classificação dos mamões por tamanho com base na massa: pequeno (S) ≤ 580 g; 580 g <meio (M) ≤ 700 g; e grande (L) > 700 g. Fonte: O autor.

Para aumentar a similaridade e precisão dos dados, neste estudo foi avaliada a correlação da densidade de cada mamão com sua altura estimada (h) e o V_e (Figura 26). A Figura 26a corresponde à relação da densidade com a altura estimada do mamão, observou-se que os valores apresentam uma correlação baixa de dados (0,22), porém, possui uma correlação linear significativa ($p < 0,05$). Os dados de densidade comparados com V_e mostraram melhor correlação linear (0,48) (Figura 26b) e correlação linear significativa ($p < 0,05$). As correlações lineares significativas indicam que a densidade é função da variação de h e V_e , portanto, as equações lineares apresentadas foram utilizadas para otimizar o cálculo da massa.

Figura 26 - Gráficos de dispersão de: (a) densidade individual (ρ_i) versus altura estimada (h); (b) densidade individual (ρ_i) versus volume total estimado (V_e); (c) massa em função da altura (M_h) versus massa real (M_r); (d) massa em função do volume (M_V) versus massa real (M_r).



Fonte: O autor.


As Figuras 26c e 26d foram geradas a partir equações observadas nestas figuras, correspondendo à massa estimada da densidade em função de h (M_h) e à massa estimada da densidade em função de V_e (M_V), respectivamente, com M_r . A comparação de M_h e M_V com M_r , mostrou uma melhor correlação linear dos dados, em comparação com a relação entre $M_{\bar{\rho}}$ e M_r (Figura 25b), conseguindo otimizar os valores de massa estimados. Essa otimização também se refletiu no parâmetro ε_x (Tabela 6), que mostra que o erro de cálculo foi diminuído. Esse resultado ocorre porque o cálculo da massa não foi realizado com base em um único valor de densidade. A predição da massa pela altura e volume da fruta, bem como a densidade individual de mamão, teve valores de erro experimental inferiores a 5%, sugerindo que essas abordagens poderiam ser utilizadas para calcular a massa do mamão a partir de imagens. Além de otimizar a correlação linear, a precisão dos dados também foi aprimorada (Figura 27). A precisão dos dados M_h sobre M_r , mostrou as diferenças que estavam entre 72,8 g e -79,3 g, com um valor percentual tolerável para a média de massa de 11,1% e 12,1%, respectivamente (Figura 27a), enquanto a precisão entre M_V cerca de M_r foi em torno de 57,4 g e -59,3 g, com uma porcentagem de erro tolerável para a média de massa de 8,8% e 9,0%, respectivamente (Figura 27b).

Tabela 6 - Estatística descritiva da massa reais e estimados em mamão.

Parâmetro	Média	σ	Min.	Max.	ϵ_x	$\sigma_{\epsilon x}$
M_r (g)	655,5	52,2	505,0	742,0		
$M_{\bar{\rho}}$ (g)	659,4	73,5	480,9	832,4	5,2	4,3
M_{ρ_i} (g)	656,9	53,5	496,0	758,7	1,6	1,2
M_h (g)	658,2	62,5	513,8	806,9	4,7	3,5
M_V (g)	656,4	42,0	537,1	739,2	3,6	2,8

M_r : massa real calculada experimentalmente, $M_{\bar{\rho}}$: massa calculada usando a densidade média, M_{ρ_i} : massa calculada usando a densidade individual, M_h : massa em função da altura da fruta, M_V : massa em função do volume da fruta, σ : desvio padrão, Min.: valor mínimo, Max.: valor máximo, ϵ_x : erro experimental, $\sigma_{\epsilon x}$: desvio padrão do erro experimental. Fonte: O autor.

Figura 27 - Bland-Altman graficos: (a) a diferença de massa em função da altura (M_h) e da massa real (M_r); e (b) massa estimada usando a densidade média ($M_{\bar{\rho}}$) e M_r .



Fonte: O autor.

De acordo com o teste de Kolmogorov-Smirnov realizado, tanto M_h quanto M_V apresentam normalidade ($p > 0,05$) (Tabela 7), então o teste T-student foi utilizado para comparar esses dados com M_h , indicando que os novos dados estimados são significativamente semelhantes ($p > 0,05$) aos valores de massa experimental.

Tabela 7 - Análise T-student para amostras relacionadas entre massa estimada e real.

Parâmetros	Significância	95% Nível de confiança da diferença média	
		Inferior	Superior
$M_h - M_r$	$p = 0,205$	-8,502	1,835
$M_V - M_r$	$p = 0,666$	-4,841	3,102

M_r : massa calculada com densidade média, M_h : massa em função da altura, M_V : massa em função do volume.

Fonte: O autor.

Por fim, observou-se que a otimização no cálculo da massa do mamão utilizando M_h e M_V (Tabela 8) permitiu melhorar a classificação dos mamões por tamanho, obtendo uma acurácia de 81,6 e 85,2, respectivamente. Esse resultado confirma que esses parâmetros poderiam ser usados para classificar o mamão por visão computacional quando comparado com $M_{\bar{p}}$.

Tabela 8 - Matriz de confusão para classificação do tamanho do mamão usando altura da fruta (M_h) e volume (M_V).

Tamanho real	Tamanho estimado (unidades)* M_h			Total	C (%)	Tamanho estimado (unidades)* M_V			Total	C (%)
	S	M	L			S	M	L		
S	29	3	0	32	90,6	30	2	0	32	93,8
M	17	73	24	114	64,0	0	80	34	114	70,2
L	0	7	65	72	90,3	0	6	66	72	91,7
Total	0	83	89	218	81,6	0	88	100	218	85,2

*Os valores foram obtidos usando valores experimentais. M_h : massa em função da altura da fruta, M_V : massa em função do volume da fruta, C (%): porcentagem da estimativa correta.

Classificação dos mamões por tamanho com base na massa: pequeno (S) ≤ 580 g; 580 g <meio (M) ≤ 700 g; e grande (L) > 700 g. Fonte: O autor.

5.3 VALIDAÇÃO DO CÓDIGO

Após desenvolver o código e observar que os dados estimados por ele são significativamente iguais aos dados obtidos em laboratório ($p > 0,05$), outras amostras fora do desenho experimental foram utilizadas para validar se o algoritmo é eficaz no uso em imagens do mamão ‘Goldem’ (Tabela 9). Para este novo conjunto de dados, a densidade média foi de 0,877 g/mL com desvio padrão de 0,020 g/mL, com densidades variando de 0,843 a 0,882 g/mL. Esses novos dados de densidade poderiam favorecer a estimativa de parâmetros, pois apresenta menor desvio em seus valores médios em relação ao design experimental realizado anteriormente ($\sigma = 0,059$ g/mL).

Em primeiro lugar, foi observado que o volume estimado apresentou similaridade estatística com o volume real calculado experimentalmente ($p > 0,05$). Embora neste caso o valor médio do erro experimental tenha sido maior em comparação com o primeiro desenho experimental ($\varepsilon_x = 1,6$ %) (Tabela 4), a estimativa contínua sendo aproximada aos valores reais do seu volume. A massa estimada com a densidade média também apresentou similaridade

estatística ($p > 0,05$), com um valor médio de erro experimental de 6,1 %, que foi maior que o primeiro estudo realizado ($\epsilon_x = 1,6$ %), porém, a estimativa continua sendo aproximada dos valores obtidos em laboratório. Como esperado, a estimativa da massa com a densidade média apresentou erros experimentais superiores aos obtidos pela massa estimada com a densidade individual, isso se deve ao fato de estar sendo utilizada uma única densidade para todas as amostras. Embora esses valores sejam estatisticamente semelhantes ($p > 0,05$), eles apresentam menor confiabilidade para a estimativa de valores, pois o erro experimental médio é superior a 10%. Para tanto, são utilizados novos modelos obtidos graficamente após a relação densidade com altura e volume (Figura 26). Esses modelos conseguiram otimizar a estimativa da massa, obtendo valores médios de erro experimental de 6,8 e 6,1 % para a massa em função da altura e volume, respectivamente, obtendo valores maiores em relação ao primeiro cálculo (Tabela 6), mas igualmente semelhantes aos valores reais ($p > 0,05$). Embora esses valores sejam menos aproximados que a massa estimada com a densidade individual, foi possível melhorar o cálculo levando em consideração a massa estimada com a densidade média.

Esses novos resultados mostram a confiabilidade do uso do algoritmo desenvolvido, pois, apesar do mesmo conjunto de amostras não estar sendo utilizado, ele continua apresentando resultados confiáveis para estimação de parâmetros.

Tabela 9 - Estatística descritiva de estimativa de volume e massa com novo conjunto de amostras para validação do código.

Amostra	V_r (mL)	M_r (g)	ρ_i (g/mL)	V_e (g/mL)	ε_x (%)	M_{ρ_i} (g)	ε_x (%)	$M_{\bar{\rho}}$ (g)	ε_x (%)	M_h (g)	ε_x (%)	M_V (g)	ε_x (%)
1	660	582,4	0,882	624,8	5,3	551,1	5,4	519,1	10,9	546,2	6,2	530,0	9,0
2	660	582,4	0,882	622,6	5,7	549,2	5,7	531,7	8,7	544,5	6,5	536,0	8,0
3	623	542,4	0,871	617,0	1,0	537,4	0,9	505,1	6,9	539,8	0,5	518,3	4,4
4	623	542,4	0,871	605,0	2,9	526,9	2,9	509,0	6,2	529,9	2,3	511,4	5,7
5	544	458,7	0,843	482,8	11,3	406,4	11,4	394,7	13,9	429,3	6,4	440,0	4,1
6	544	458,7	0,843	489,8	10,0	412,9	10,0	379,1	17,3	434,8	5,2	444,5	3,1
7	640	582,3	0,910	613,0	4,2	544,1	6,6	522,3	10,3	498,6	14,4	529,6	9,0
8	640	582,3	0,910	615,7	3,8	546,4	6,2	526,9	9,5	505,8	13,1	550,7	5,4
Valor médio			0,877		5,5		6,1		10,5		6,8		6,1
σ			0,020		2,6		2,4		2,7		3,5		1,9

V_r : volume real calculado experimentalmente (mL), V_e : volume estimado (mL), M_r : massa real calculada experimentalmente (g), $M_{\bar{\rho}}$: massa calculada usando a densidade média (g), M_{ρ_i} : massa calculada usando a densidade individual (g), M_h : massa em função da altura da fruta, M_V : massa em função do volume da fruta, σ : desvio padrão, ε_x : erro experimental. Fonte: O auto

6 CONCLUSÃO

A metodologia computacional por visão artificial mostrou-se uma ferramenta eficaz e não destrutiva para classificar o mamão de acordo com a cor da pele, volume. No caso da massa, foi demonstrada maior confiabilidade no processo de classificação após a otimização deste parâmetro. O processo de classificação baseado em três estágios de maturação dos mamões do canal a * (espaço de cores CIElab) apresentou alta precisão (em torno de 95%). Em relação aos parâmetros dimensionais (volume e massa), também foi demonstrado o potencial de uso da metodologia computacional desenvolvida na presente pesquisa. Dessa forma, o volume estimado e o volume real foram significativamente semelhantes ($p > 0,05$). Por fim, a estimativa da massa do mamão foi mais difícil, pois depende de sua densidade. Portanto, a estimativa da massa do mamão pode ser mais imprevisível do que o volume, visto que esta fruta apresenta um espaço interno impossível de ser medido com a tecnologia de visão artificial utilizada neste estudo, porém o cálculo da massa foi otimizado com sucesso através de regressões lineares. Com base nos resultados obtidos na presente pesquisa, é possível sugerir a aplicação do código computacional desenvolvido para classificar o mamão com base em sua maturação, volume e massa.

6.1 SUGESTÕES DE TRABALHOS FUTUROS

A partir desta pesquisa, sugere-se a realização dos seguintes estudos:

- Classificar os mamões de acordo com os danos superficiais por meio de metodologias computacionais.
- Estudar o crescimento de fungos na superfície dos mamões mediante metodologias computacionais.
- Realizar um estudo para correlacionar o estado de maturidade com a quantidade de compostos físico-químicos, como betacaroteno, fenólicos, e estimar a taxa de produção de etileno.
- Criar um aplicativo no qual as diferentes características do mamão sejam analisadas ao vivo por meio de vídeos.
- Aplicar a metodologia utilizada neste estudo em outros vegetais.
- Integrar o Machine Learning ao código de programação para gerar um aplicativo mais eficiente.

REFERENCIAS

Accenture. (2020). THE COMING AI PRODUCTIVITY BOOM And how federal agencies can make the most of it.

Ahmad, U. (2017). The use of color distribution analysis for ripeness prediction of Golden Apollo melon. In *Journal of Applied Horticulture* (www.horticultureresearch.net) *Journal of Applied Horticulture* (Vol. 19). www.horticultureresearch.net

Ali, M. A. H., & Thai, K. W. (2017). Automated Fruit Grading System. 2017 IEEE 3rd International Symposium in Robotics and Manufacturing Automation (ROMA).

Alkreem, M. H., & Karim, A. A. (2021). Feature Selection Using Artificial Bee Colony for Fruit Classification. *Journal of Physics: Conference Series*, 1818(1).
<https://doi.org/10.1088/1742-6596/1818/1/012062>

Alosaimi, W., Alyami, H., & Uddin, M. I. (2021). PeachNet: Peach diseases detection for automatic harvesting. *Computers, Materials and Continua*, 67(2), 1665–1677.
<https://doi.org/10.32604/cmc.2021.014950>

Ananthanarayana, T., Ptucha, R., & Kelly, S. C. (2020). Deep Learning based Fruit Freshness Classification and Detection with CMOS Image sensors and Edge processors. IS and T International Symposium on Electronic Imaging Science and Technology, 2020(12).
<https://doi.org/10.2352/ISSN.2470-1173.2020.12.FAIS-172>

Arakeri, M. P., & Lakshmana. (2016). Computer Vision Based Fruit Grading System for Quality Evaluation of Tomato in Agriculture industry. *Procedia Computer Science*, 79, 426–433. <https://doi.org/10.1016/j.procs.2016.03.055>

Arias, R., Lee, T. C., Logendra, L., & Janes, H. (2000). Correlation of lycopene measured by HPLC with the L*, a*, b* color readings of a hydroponic tomato and the relationship of

maturity with color and lycopene content. *Journal of Agricultural and Food Chemistry*, 48(5), 1697–1702. <https://doi.org/10.1021/jf990974e>

Atencio Ortíz, P. S. (2009). Desarrollo de un sistema de visión artificial para el control de calidad del mango de azúcar de exportación.

Barreto, G. P. M., Fabi, J. P., de Rosso, V. v., Cordenunsi, B. R., Lajolo, F. M., do Nascimento, J. R. O., & Mercadante, A. Z. (2011). Influence of ethylene on carotenoid biosynthesis during papaya postharvesting ripening. *Journal of Food Composition and Analysis*, 24(4–5), 620–624. <https://doi.org/10.1016/j.jfca.2011.02.006>

Basulto, F. S., Duch, E. S., Gil, F. E., Plaza, R. D., Saavedra, A. L., & Santamaría, J. M. (2009). Quality changes during different ripening stages of red skin papaya. *INTERCIENCIA*, 34(8), 583–588. <https://www.researchgate.net/publication/261064485>

Behera, S. K., Rath, A. K., & Sethy, P. K. (2021). Maturity status classification of papaya fruits based on machine learning and transfer learning approach. *Information Processing in Agriculture*, 8(2), 244–250. <https://doi.org/10.1016/j.inpa.2020.05.003>

Bhargava, A., & Bansal, A. (2021a). Fruits and vegetables quality evaluation using computer vision: A review. In *Journal of King Saud University - Computer and Information Sciences* (Vol. 33, Issue 3, pp. 243–257). King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2018.06.002>

Bhargava, A., & Bansal, A. (2021b). Fruits and vegetables quality evaluation using computer vision: A review. In *Journal of King Saud University - Computer and Information Sciences* (Vol. 33, Issue 3, pp. 243–257). King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2018.06.002>

Biffi, L. J., Mitishita, E., Liesenberg, V., dos Santos, A. A., Gonçalves, D. N., Estrabis, N. V., Silva, J. de A., Osco, L. P., Ramos, A. P. M., Centeno, J. A. S., Schimalski, M. B., Rufato, L., Neto, S. L. R., Junior, J. M., & Gonçalves, W. N. (2021). Article atss deep learning-based

approach to detect apple fruits. *Remote Sensing*, 13(1), 1–23.

<https://doi.org/10.3390/rs13010054>

Bland, J. M., & Altman, D. G. (1999). Measuring agreement in method comparison studies. *Statistical Methods in Medical Research*, 8(2), 135–160.

<https://doi.org/10.1177/096228029900800204>

Blasco, J., Cubero, S., Gómez-Sanchís, J., & Moltó, E. (2010). Avances en visión artificial automática de productos hortofrutícolas. *Horticultura Global*, 288, 48–50.

Bonilla, J., Pruetto, F., & Pérez, C. (2017). Mass and Volume Estimation of Passion Fruit using Digital Images. *IEEE LATIN AMERICA TRANSACTIONS*, 15(2), 275–282.

Bozokalfa, M. K., & Kilic, M. (2010). Mathematical modeling in the estimation of pepper (*Capsicum annum* l.) fruit volume. *Journal of agricultural research*, 70(4), 626–632.

Braga, H. (2020). Mamão: a}Aspectos econômicos, biológicos e potencialidades no processamento para obtenção do néctar. *Enciclopédia Biosfera*, 17(30).

https://doi.org/10.18677/encibio_2020a12

Bron, I. U., Jacomino, A. P., Bron, I. U., & Jacomino, A. P. (2006). Ripening and quality of “Golden” papaya fruit harvested at different maturity stages. *Braz. J. Plant Physiol*, 18(3), 389–396.

C Minds. (2020). Artificial intelligence for social good in latin america and the caribbean: The Regional Landscape and 12 Country Snapshots. <https://www.iadb.org/>

Cárdenas-Pérez, S., Chanona-Pérez, J., Méndez-Méndez, J. v., Calderón-Domínguez, G., López-Santiago, R., Perea-Flores, M. J., & Arzate-Vázquez, I. (2017). Evaluation of the ripening stages of apple (Golden Delicious) by means of computer vision system. *Biosystems Engineering*, 159, 46–58. <https://doi.org/10.1016/j.biosystemseng.2017.04.009>

Castro, W., Oblitas, J., De-La-Torre, M., Cotrina, C., Bazan, K., & Avila-George, H. (2019). Classification of Cape Gooseberry Fruit According to its Level of Ripeness Using Machine Learning Techniques and Different Color Spaces. *IEEE Access*, 7, 27389–27400.

<https://doi.org/10.1109/ACCESS.2019.2898223>

Chanco Gamonal, A. E. (2020). Diseño de un sistema por visión artificial para determinar la calidad de mandarinas.

Chen, W. L., Kan, C. D., Lin, C. H., Chen, Y. S., & Mai, Y. C. (2017). Hypervolemia screening in predialysis healthcare for hemodialysis patients using fuzzy color reason analysis. *International Journal of Distributed Sensor Networks*, 13(1).

<https://doi.org/10.1177/1550147716685090>

Chen, Y., An, X., Gao, S., Li, S., & Kang, H. (2021). A Deep Learning-Based Vision System Combining Detection and Tracking for Fast On-Line Citrus Sorting. *Frontiers in Plant Science*, 12. <https://doi.org/10.3389/fpls.2021.622062>

Constante Prócel, P. N., & Gordón Garcés, A. M. (2015). Diseño e implementación de un sistema de visión artificial para clasificación de al menos tres tipos de frutas.

Corvalán, J. G. (2018). Inteligencia artificial: Retos, desafíos y oportunidades - Prometea: La primera inteligencia artificial de Latinoamérica al servicio de la Justicia. In *Revista de Investigaciones Constitucionales* (Vol. 5, Issue 1, pp. 295–316). Universidade Federal do Parana. <https://doi.org/10.5380/rinc.v5i1.55334>

Costa, C., Antonucci, F., Pallottino, F., Aguzzi, J., Sun, D. W., & Menesatti, P. (2011). Shape Analysis of Agricultural Products: A Review of Recent Research Advances and Potential Application to Computer Vision. In *Food and Bioprocess Technology* (Vol. 4, Issue 5, pp. 673–692). <https://doi.org/10.1007/s11947-011-0556-0>

Cubero García, S. (2012). Diseño e implementación de nuevas tecnologías basadas en visión artificial para la inspección no destructiva de la calidad de fruta en campo y mínimamente procesada.

Cubero, S., Diago, M. P., Blasco, J., Tardáguila, J., Millán, B., & Aleixos, N. (2014). A new method for pedicel/peduncle detection and size assessment of grapevine berries and other fruits by image analysis. *Biosystems Engineering*, 117(C), 62–72.

<https://doi.org/10.1016/j.biosystemseng.2013.06.007>

Cuevas, Erik., Zaldívar, Daniel., & Pérez-Cisneros, Marco. (2010). Procesamiento digital de imágenes usando MatLAB & Simulink. Alfaomega.

Dang, H., Song, J., & Guo, Q. (2010). A fruit size detecting and grading system based on image processing. *Proceedings - 2010 2nd International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2010*, 2, 83–86.

<https://doi.org/10.1109/IHMSC.2010.120>

de Frías, C. J. (2019). Visión artificial aplicada en la identificación de objetos y su parametrización geométrica.

de Luna, R. G., Dadios, E. P., Bandala, A. A., & Vicerra, R. R. P. (2019). Size classification of tomato fruit using thresholding, machine learning and deep learning techniques. *Agrivita*, 41(3), 586–596. <https://doi.org/10.17503/agrivita.v41i3.2435>

ECLAC. (2014). Latin America and the Caribbean in the world economy.

European Commission. (2021). Report from the commission to the european parliament, the council, the european economic and social committee and the committee of the regions.

Fabi, J. P., & do Prado, S. B. R. (2019). Fast and furious: Ethylene-triggered changes in the metabolism of papaya fruit during ripening. In *Frontiers in Plant Science (Vol. 10)*. Frontiers Media S.A. <https://doi.org/10.3389/fpls.2019.00535>

Fabi, J. P., Passanezi, M. L., & Gomez, A. (2010). Papaya, Mango and Guava Fruit Metabolism during Ripening: Postharvest Changes Affecting Tropical Fruit Nutritional Content and Quality. *Fresh Produce*, 4(1), 56–66.

<https://www.researchgate.net/publication/233969256>

FAO. (2007). MANUAL DE MANEJO POSTCOSECHA DE FRUTAS TROPICALES.

<http://www.fao.org/inpho/content/documents/vlibrary/ac304s/ac304s00.htm>

FAO. (2019a). 10 World's Biggest Papaya-Producing Countries.

FAO. (2019b). Análisis del mercado de la principales frutas tropicales.

FAOSTAT. (2019). Crops and livestock products: papayas.

<https://www.fao.org/faostat/en/#data/QCL/visualize>

Flôr Vieira, A. C. (2020). Desenvolvimento e caracterização de filmes e coberturas à base de hidroxipropilmetilcelulose e nanopartículas de prata com propriedades antifúngicas para estender a vida pós colheita do mamão papaya (carica papaya).

Fu, L., Sun, S., Li, R., & Wang, S. (2016). Classification of kiwifruit grades based on fruit shape using a single camera. *Sensors (Switzerland)*, 16(7). <https://doi.org/10.3390/s16071012>

Fuentes, G., & Santamaría, J. M. (2014). Papaya (*Carica papaya* L.): Origin, domestication, and production. In *Genetics and Genomics of Papaya* (pp. 3–15). Springer New York.

https://doi.org/10.1007/978-1-4614-8087-7_1

Garcia, M. B., Ambat, S., & Adao, R. T. (2019). Tomayto, Tomahto: A Machine Learning Approach for Tomato Ripening Stage Identification Using Pixel-Based Color Image Classification. 2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM).

García Santillán, I. D. (2008). *Visión Artificial y Procesamiento Digital de Imágenes usando Matlab*.

Gómez-Sanchis, J., Moltó, E., Camps-Valls, G., Gómez-Chova, L., Aleixos, N., & Blasco, J. (2008). Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. *Journal of Food Engineering*, 85(2), 191–200. <https://doi.org/10.1016/j.jfoodeng.2007.06.036>

Hassan, N. M. H., & Nashat, A. A. (2019). New effective techniques for automatic detection and classification of external olive fruits defects based on image processing techniques. *Multidimensional Systems and Signal Processing*, 30(2), 571–589. <https://doi.org/10.1007/s11045-018-0573-5>

Huynh, T., Tran, L., & Dao, S. (2020). Real-time size and mass estimation of slender axisymmetric fruit/vegetable using a single top view image. *Sensors (Switzerland)*, 20(18), 1–24. <https://doi.org/10.3390/s20185406>

Ibraheem, N. A., Hasan, M. M., Khan, R. Z., & Mishra, P. K. (2012). Understanding Color Models: A Review. *ARNP Journal of Science and Technology*, 2(3). <http://www.ejournalofscience.org>

Ibrahim, M. F., Sa'ad, F. S. A., Zakaria, A., & Shakaff, A. Y. M. (2016). In-line sorting of harumanis mango based on external quality using visible imaging. *Sensors (Switzerland)*, 16(11). <https://doi.org/10.3390/s16111753>

Ileri, D., Belal, E., Okinda, C., Makange, N., & Ji, C. (2019). A computer vision system for defect discrimination and grading in tomatoes using machine learning and image processing. *Artificial Intelligence in Agriculture*, 2, 28–37. <https://doi.org/10.1016/j.aiia.2019.06.001>

Jana, S., Parekh, R., & Sarkar, B. (2020). A De novo approach for automatic volume and mass estimation of fruits and vegetables. *Optik*, 200. <https://doi.org/10.1016/j.ijleo.2019.163443>

Javadikia, H., Sabzi, S., & Rabbani, H. (2017). Machine vision based expert system to estimate orange mass of three varieties. *International Journal of Agricultural and Biological Engineering*, 10(2), 132–140. <https://doi.org/10.3965/j.ijabe.20171002.1737>

Kangune, K., VKulkarni, V., & Kosamkar, P. (2019). Automated estimation of grape ripeness. *Asian Journal of Convergence in Technology*, 5(1), 1–6. www.asianssr.org

Kondo, N. (2010). Automation on fruit and vegetable grading system and food traceability. *Trends in Food Science and Technology*, 21(3), 145–152. <https://doi.org/10.1016/j.tifs.2009.09.002>

León, K., Mery, D., Pedreschi, F., & León, J. (2006). Color measurement in L*a*b* units from RGB digital images. *Food Research International*, 39(10), 1084–1091. <https://doi.org/10.1016/j.foodres.2006.03.006>

Li, S., Luo, H., Hu, M., Zhang, M., Feng, J., Liu, Y., Dong, Q., & Liu, B. (2019). Optical non-destructive techniques for small berry fruits: A review. *Artificial Intelligence in Agriculture*, 2, 85–98. <https://doi.org/10.1016/j.aiia.2019.07.002>

Ly, B. C. K., Dyer, E. B., Feig, J. L., Chien, A. L., & del Bino, S. (2020). Research Techniques Made Simple: Cutaneous Colorimetry: A Reliable Technique for Objective Skin Color Measurement. In *Journal of Investigative Dermatology* (Vol. 140, Issue 1, pp. 3-12.e1). Elsevier B.V. <https://doi.org/10.1016/j.jid.2019.11.003>

Malacara, D. (2011). *Color Vision and Colorimetry: Theory and Applications* (Vol. 2).

Martins, G. F., Fabi, J. P., Mercadante, A. Z., & de Rosso, V. V. (2016). The ripening influence of two papaya cultivars on carotenoid biosynthesis and radical scavenging capacity. *Food Research International*, 81, 197–202. <https://doi.org/10.1016/j.foodres.2015.11.027>

Melo, M. C. (2019). Parâmetros físicos, físico-químicos e reológicos do mamão (carica papaya l.) armazenado em diferentes temperaturas.

Mohazzab, P. (2017). Archimedes' Principle Revisited. *Journal of Applied Mathematics and Physics*, 05(04), 836–843. <https://doi.org/10.4236/jamp.2017.54073>

Nature Index. (2020). Top 100 academic institutions in artificial intelligence.

Nyalala, I., Okinda, C., Nyalala, L., Makange, N., Chao, Q., Chao, L., Yousaf, K., & Chen, K. (2019). Tomato volume and mass estimation using computer vision and machine learning algorithms: Cherry tomato model. *Journal of Food Engineering*, 263, 288–298. <https://doi.org/10.1016/j.jfoodeng.2019.07.012>

Oliveira, M. G., Mazonra, L. M., Souza, A. F., Silva, G. M. C., Correa, S. F., Santos, W. C., Saraiva, K. D. C., Teixeira, A. J., Melo, D. F., Silva, M. G., Silva, M. A. P., Arrabaça, J. D. C., Costa, J. H., & Oliveira, J. G. (2015). Involvement of AOX and UCP pathways in the post-harvest ripening of papaya fruits. *Journal of Plant Physiology*, 189, 42–50. <https://doi.org/10.1016/j.jplph.2015.10.001>

Omid, M., Khojastehnazhand, M., & Tabatabaeefar, A. (2010). Estimating volume and mass of citrus fruits by image processing technique. *Journal of Food Engineering*, 100(2), 315–321. <https://doi.org/10.1016/j.jfoodeng.2010.04.015>

Østerlund, C., Jarrahi, M. H., Willis, M., Boyd, K., & T. Wolf, C. (2021). Artificial intelligence and the world of work, a co-constitutive relationship. *Journal of the Association for Information Science and Technology*, 72(1), 128–135. <https://doi.org/10.1002/asi.24388>

Pandey, R., Gamit, N., & Naik, S. (2014). A Novel Non-Destructive Grading method for Mango (*Mangifera Indica* L.) using Fuzzy Expert System. *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 1–8.

Pattnayak, S. B., & Patra, T. K. (2020). An Image Processing Approach to Detect Fruit Damage. *International Research Journal of Engineering and Technology*, 7(7), 667–671. www.irjet.net

Peixoto, A. de M. (2008). Fisiologia e conservação pós colheita de mamão ‘Golden’ Tratado com 1-metilciclopropeno em diferentes estádios de Maturação.

Perkins-Veazie, P., Collins, J. K., Davis, A. R., & Roberts, W. (2006). Carotenoid content of 50 watermelon cultivars. *Journal of Agricultural and Food Chemistry*, 54(7), 2593–2597. <https://doi.org/10.1021/jf052066p>

Pigozzi, M. T., Silva, V. M., Mendes, F. Q., de Oliveira, I. R. N., E Moraes, A. R. F., & Lopes, E. A. (2021). Post-harvest quality of papaya coated with polivinilic alcohol and maize starch. *Ciencia e Agrotecnologia*, 45, 1–8. <https://doi.org/10.1590/1413-7054202145019120>

Poupeau, F., Rosenberger, C., Laurent, H., Emile, B., & Fachaux, J. (2003). Calibration and Quality Control of Cherries by Artificial Vision. *Proceedings, Sixth International Conference on Quality Control by Artificial Vision*, 5132, 359–366. <http://proceedings.spiedigitallibrary.org/>

Puerta-Díaz, M., de Mira, B. S., Martínez-Ávila, D., Ovalle-Perandones, M. A., & Grácio, M. C. C. (2021). Natural language processing in information metric studies: An analysis of the articles indexed by the web of science (2000-2019). *Encontros Bibli*, 26. <https://doi.org/10.5007/1518-2924.2021.e76886>

Reis Neto, S. A. (2006). Qualidade pós-colheita do mamão (carica papaya) cv. Golden armazenado sob atmosferas modificadas.

Reset. (2020). Estos son los países líderes en inteligencia artificial en América Latina y en otras regiones del mundo.

Rodriguez Morales, R., & Sossa Azuela, J. H. (2011). Procesamiento y Análisis Digital de Imágenes. <https://www.researchgate.net/publication/259364462>

Rojas-Garbanzo, C., Gleichenhagen, M., Heller, A., Esquivel, P., Schulze-Kaysers, N., & Schieber, A. (2017). Carotenoid Profile, Antioxidant Capacity, and Chromoplasts of Pink Guava (*Psidium guajava* L. Cv. 'Criolla') during Fruit Ripening. *Journal of Agricultural and Food Chemistry*, 65(18), 3737–3747. <https://doi.org/10.1021/acs.jafc.6b04560>

Saldaña, E., Siche, R., Luján, M., & Quevedo, R. (2013). Review: computer vision applied to the inspection and quality control of fruits and vegetables. *Brazilian Journal of Food Technology*, 16(4), 254–272. <https://doi.org/10.1590/s1981-67232013005000031>

Sigurdson, G. T., Tang, P., & Giusti, M. M. (2017). Natural Colorants: Food Colorants from Natural Sources. *Annual Review of Food Science and Technology*, 8, 261–280. <https://doi.org/10.1146/annurev-food-030216-025923>

Silva, C. E. de F., & Abud, A. K. de S. (2017). Tropical Fruit pulps: Processing, product standardization and main control parameters for quality assurance. *Brazilian Archives of Biology and Technology*, 60. <https://doi.org/10.1590/1678-4324-2017160209>

UNESCO. (2019). Greater Participation of Civil Society in Peru Will Inspire Better Cultural Policies.

Utai, K., Nagle, M., Hämmerle, S., Spreer, W., Mahayothee, B., & Müller, J. (2019). Mass estimation of mango fruits (*Mangifera indica* L., cv. 'Nam Dokmai') by linking image processing and artificial neural network. *Engineering in Agriculture, Environment and Food*, 12(1), 103–110. <https://doi.org/10.1016/j.eaef.2018.10.003>

van den Broek, E. L. (2005). Human-centered content-based image retrieval. <https://www.researchgate.net/publication/228719004>

van Eck, J. W., van der Heijden, G. W. A. M., & Polder, G. (1998). Accurate measurement of size and shape of cucumber fruits with image analysis. *Journal of Agricultural and Engineering Research*, 70(4), 335–343. <https://doi.org/10.1006/jaer.1998.0285>

Vazquez-Cruz, M. A., Pacheco-Torres, I., Miranda-Lopez, R., Cornejo-Perez, O., Osornio-Rios, R., Romero-Troncoso, R., & Guevara-Gonzales, R. G. (2010). Potential of mathematical modeling in fruit quality. *African Journal of Biotechnology*, 9(3), 260–267.

<http://www.academicjournals.org/AJB>

Vieira, A. C. F., de Matos Fonseca, J., Menezes, N. M. C., Monteiro, A. R., & Valencia, G. A. (2020). Active coatings based on hydroxypropyl methylcellulose and silver nanoparticles to extend the papaya (*Carica papaya* L.) shelf life. *International Journal of Biological Macromolecules*, 164, 489–498. <https://doi.org/10.1016/j.ijbiomac.2020.07.130>

Villaseñor-Aguilar, M. J., Botello-Álvarez, J. E., Pérez-Pinal, F. J., Cano-Lara, M., León-Galván, M. F., Bravo-Sánchez, M. G., & Barranco-Gutierrez, A. I. (2019). Fuzzy Classification of the Maturity of the Tomato Using a Vision System. *Journal of Sensors*, 2019, 1–13. <https://doi.org/10.1155/2019/3175848>

Wegehenkel, M., & Mirschel, W. (2006). Crop growth, soil water and nitrogen balance simulation on three experimental field plots using the Opus model - A case study. *Ecological Modelling*, 190(1–2), 116–132. <https://doi.org/10.1016/j.ecolmodel.2005.02.020>

