



**MARCO ANTONIO ZANELLA**

**VISÃO COMPUTACIONAL PARA CLASSIFICAR A  
MATURAÇÃO DOS FRUTOS DE CAFÉ NO PROCESSO DE  
COLHEITA MECANIZADA**

**LAVRAS - MG  
2023**

**MARCO ANTONIO ZANELLA**

**VISÃO COMPUTACIONAL PARA CLASSIFICAR A MATURAÇÃO DOS FRUTOS  
DE CAFÉ NO PROCESSO DE COLHEITA MECANIZADA**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração Máquinas e Mecanização Agrícola, para obtenção de título de Doutor.

Prof. Dr. Fábio Moreira da Silva  
Orientador

**LAVRAS - MG  
2023**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Zanella, Marco Antonio.

Visão computacional para classificar a maturação dos frutos de café no processo de colheita mecanizada / Marco Antonio Zanella. - 2023.

68 p.

Orientador(a): Fábio Moreira da Silva.

Tese (doutorado) - Universidade Federal de Lavras, 2023.  
Bibliografia.

1. Maturação. 2. Processamento de imagem. 3. Inteligência artificial. I. Moreira da Silva, Fábio. II. Título.

**MARCO ANTONIO ZANELLA**

**VISÃO COMPUTACIONAL PARA CLASSIFICAR A MATURAÇÃO DOS FRUTOS  
DE CAFÉ NO PROCESSO DE COLHEITA MECANIZADA**

**COMPUTATIONAL VISION TO CLASSIFY THE COFFEE FRUITS RIPENESS IN  
THE MECHANIZED HARVESTING PROCESS**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Máquinas e Mecanização Agrícola, para obtenção de título de Doutor.

APROVADA em 28 de abril de 2023  
Prof. Dr. Gabriel Araújo e Silva Ferraz UFLA  
Prof. Dr. Rafael De Oliveira Faria UFLA  
Prof. Dr. Evandro Pereira Da Silva UNILAVRAS  
Prof. Dr. Manassés Ribeiro IFC

Prof. Dr. Fábio Moreira da Silva  
Orientador

**LAVRAS - MG  
2023**

Aos meus pais, Salete e Antônio,  
por me ensinarem valores para a vida e  
por sempre incentivarem os meus estudos.

Dedico

## AGRADECIMENTOS

Agradeço a Deus pelas infinitas bênçãos concedidas.

Aos meus pais, Salete e Antônio, pelo incentivo a seguir estudando e às minhas irmãs Silvia, Elisa e Renata pela amizade e carinho.

À minha esposa Daniele, pelo amor, carinho e companheirismo durante todos os momentos e sempre.

Ao meu orientador, Prof. Dr. Fábio Moreira da Silva, por seu companheirismo, dedicação e paciência.

Ao amigo Prof. Dr. Ruben Ruiz-Gonzalez, que tanto me ajudou, pela amizade, incentivo e companheirismo.

Ao Prof. Dr. Jaime Gomez-Gil pelo acolhimento, incentivo, ensinamentos, dedicação e paciência. Não tenho dúvidas que minha formação não seria a mesma sem sua participação.

Aos amigos da Universidad de Valladolid, Prof. Dr. Javier, Mikel, Javier e Miguel pela amizade, companheirismo e troca de informações.

Aos amigos da CEIFA, em especial ao amigo e colega Leomar, pela ajuda essencial para a realização dos trabalhos.

Aos professores do Departamento de Engenharia Agrícola/UFLA Prof. Dr. Marcelo, Prof. Dr. Gabriel, Prof. Dr. Rafael e o Prof. Dr. Carlos Volpato pela convivência.

Aos técnicos Helen, Josi, André, Amanda e Pedro e, em especial, ao Eder pela ajuda na fabricação do dispositivo.

Aos amigos da pós-graduação Luana, Miguel, Marcia e Diego pela convivência e troca de informações.

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG).

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

À Universidade Federal de Lavras (UFLA), à Escola de Engenharias e ao Programa de Pós-Graduação em Engenharia Agrícola (PPGEA) por me proporcionarem as condições para que o doutorado fosse o melhor possível.

Aos proprietários e aos funcionários das fazendas que visitei, Fazenda Cafua e Fazenda Colina, que tiveram a disponibilidade e paciência para permitir a realização de testes e coleta de dados.

Aos membros da banca de avaliação e da banca de qualificação que certamente contribuíram para o desenvolvimento e conclusão desse trabalho.

A todos que de uma forma contribuíram para a realização do doutorado.

Muito obrigado!

*“Quem tem menos medo de sofrer, tem maiores possibilidades de ser feliz.”*

(Valter Hugo Mãe)

## RESUMO

O café é um dos produtos agrícolas mais comercializados e consumidos no mundo, fundamental para o desenvolvimento socioeconômico do Brasil. A colheita do café é um processo essencial na cadeia produtiva e, corresponde por aproximadamente metade dos custos totais de produção. Nesse sentido, esta pesquisa teve como objetivo classificar frutos de café quanto ao grau de maturação durante o processo de colheita mecanizada utilizando técnicas de visão computacional. Vídeos dos frutos de café colhidos foram obtidos durante o processo de colheita mecanizada na safra de 2022. A coleta de dados ocorreu sobre a espécie arábica, variedade Bourbon Amarelo, cultivada na Fazenda Cafua no município de Ijaci, localizada na região Sul de Minas Gerais. Para a coleta de imagens, foi desenvolvido um dispositivo instalado sobre a esteira transversal da colhedora, com acoplamento de uma câmera em um suporte para reduzir os efeitos da vibração da colhedora de café e com um sistema iluminação por led para a iluminação dos frutos durante a obtenção dos vídeos. Para o processamento das imagens coletadas foram realizadas duas abordagens, (i) com o desenvolvimento de um algoritmo utilizando técnicas de visão computacional e (ii) utilizando um algoritmo de detecção de objetos de última geração o YOLOv7. O algoritmo de visão computacional foi capaz de detectar e classificar frutos de café de acordo com os seguintes graus de maturação: não maduro e maduro. A precisão média para as classes de maturação do café não maduro e maduro foi de 72% e 70%. Com algoritmo não foi possível classificar os frutos da classe demasiado maduro. O algoritmo de detecção de objetos denominado YOLOv7 foi implementado para a detecção e classificação dos frutos de café em três classes: não maduro, maduro e demasiado maduro. A rede YOLOv7 apresentou capacidade superior com valores de F1-score de 90%, 95% e 75% para as classes não maduro, maduro e demasiado maduro, respectivamente. Com a classificação da maturação dos frutos de café colhidos é possível obter um índice de maturação dos frutos durante o processo de colheita mecanizada. Além disso, os resultados desse estudo podem contribuir para o desenvolvimento de sistema embarcado para ser utilizado na coleta de dados durante a colheita mecanizada do café.

**Palavras-chave:** Maturação. Processamento de Imagens. Inteligência Artificial.



## ABSTRACT

Coffee is one of the most commercialized and consumed agricultural products in the world, fundamental for the socioeconomic development of Brazil. Coffee harvesting is an essential process in the production chain and accounts for approximately half of total production costs. In this sense, this research aimed to classify coffee fruits according to the degree of maturation during the mechanized harvesting process using computer vision techniques. Videos of the harvested coffee fruits were obtained during the mechanized harvesting process in the 2022 harvest. Data collection took place on the Arabica species, variety Bourbon Amarelo, cultivated at Fazenda Cafua in the municipality of Ijaci, located in the southern region of Minas Gerais. For the collection of images, a device installed on the transverse mat of the harvester was developed, with a camera attached to a support to reduce the effects of the vibration of the coffee harvester and with a LED lighting system for illuminating the fruits during harvesting. obtaining the videos. Two approaches were used to process the collected images, (i) with the development of an algorithm using computer vision techniques and (ii) using a state-of-the-art object detection algorithm, YOLOv7. The computer vision algorithm was able to detect and classify coffee fruits according to the following degrees of maturation: unripe and ripe. The average precision for the unripe and mature coffee maturation classes was 72% and 70%. With algorithm it was not possible to classify the fruits of the class too ripe. The object detection algorithm called YOLOv7 was implemented for the detection and classification of coffee fruits into three classes: unripe, ripe and overripe. The YOLOv7 network showed superior capacity with F1-score values of 90%, 95% and 75% for the unripe, mature and overripe classes, respectively. With the classification of the maturation of the harvested coffee fruits, it is possible to obtain an index of fruit maturation during the mechanized harvesting process. In addition, the results of this study can contribute to the development of an embedded system to be used in data collection during mechanized coffee harvesting.

**Keywords:** Ripeness. Image processing. Artificial Intelligence.

## LISTA DE FIGURAS

<b>Figura 1</b> – Ciclo fenológico bianual do cafeeiro arábica nas condições climáticas tropicais do Brasil. ....	19
<b>Figura 2</b> – Imagem de uma colhedora de café. (a) Colhedora de café vista frontal e (b) vista da parte traseira. ....	23
<b>Figura 3</b> – Imagem de dispositivo para coleta de imagens de laranjas colhidas. a) Câmera e lâmpadas. b) Sistema de coleta de imagens instalada na bancada de testes. ....	25
<b>Figura 4</b> – Exemplo de uma estrutura de rede neural convolucional. ....	28
<b>Figura 5</b> – Processo de detecção de rede YOLO. ....	31
<b>Figura 6</b> – (a) Simulação de caixas delimitadoras previstas pela rede. (b) Remoção das caixas delimitadores redundantes após a ação da função NMS. ....	31
<b>Figura 7</b> – Utilizando o banco de dados MS COCO o gráfico apresenta a comparação de desempenho do modelo YOLOv7 em relação a outros detectores de objetos em tempo real. ....	33
<b>Figura 8</b> – Imagens de frutos de café representantes de cada uma das classes utilizadas nesse estudo. (a) fruto não maduro da cor verde, (b) fruto maduro da cor amarelo e (c) fruto demasiado maduro da cor marrom. ....	36
<b>Figura 9</b> – Dispositivo para captura de imagens dos frutos de café colhidos. ....	37
<b>Figura 10</b> – Dispositivo acoplado na máquina colhedora de café para coleta de imagens. (a) Imagem lateral do dispositivo acoplado na máquina colhedora sobre a esteira transversal de transporte dos frutos colhidos. (b) Vista traseira da máquina colhedora de café com o dispositivo acoplado, localizado na parte superior da máquina e sobre a esteira transversal. ....	38
<b>Figura 11</b> – As etapas da operação de classificação da maturação dos frutos de café colhidos. ....	39
<b>Figura 12</b> – Interface da ferramenta de anotação para dados de entrada na rede YOLO e exemplo de imagem anotada. ....	41
<b>Figura 13</b> – Imagem dos módulos EELAN em que os módulos ELAN-1 estão presentes na parte backbone e os módulos ELAN-2 estão presentes na parte neck da rede. ....	42
<b>Figura 14</b> – Figura representando os módulos que compõe a estrutura original da rede YOLOv7. ....	43
<b>Figura 15</b> - Imagem representativa da obtenção dos vídeos para a validação cruzada. ....	45
<b>Figura 16</b> – Imagem dos frutos de café na esteira transportadora. ....	48
<b>Figura 17</b> – O resultado de diferentes etapas do processamento, (a) imagem original, (b) imagem em escala de cores HSV, (c) máscara, (d) binarização, (e) remoção de ruídos, (f) abertura por reconstrução, (g) identificação do fruto, e (f) acompanhamento de movimento. ....	49
<b>Figura 18</b> – Imagem dos frutos na esteira transportadora. (a) e (b) são imagens originais, (c) e (d) são os resultados da classificação para os frutos em grau de maturação maduros e não maduros, respectivamente. ....	51

<b>Figura 19</b> – Curvas de precisão do modelo de detecção YOLOv7 para as três classes e para todas juntas. .....	53
<b>Figura 20</b> – Curvas de recall do modelo de detecção YOLOv7 para as três classes e para todas juntas. .....	54
<b>Figura 21</b> – Curvas de precisão-recall do modelo de detecção YOLOv7 para as três classes e para todas juntas. ....	55
<b>Figura 22</b> – Curvas de F1-score do modelo de detecção YOLOv7 para as três classes e para todas juntas. .....	56
<b>Figura 23</b> – Imagens resultantes da validação. (a) e (b) são imagens originais, (c) e (d) são os resultados da classificação do grau de maturação dos frutos. ....	58

## LISTA DE TABELAS

<b>Tabela 1</b> – Lista de publicações selecionadas (2018-2023) como base de referência para o desenvolvimento deste estudo.....	33
<b>Tabela 2</b> – Resultados da quantificação dos frutos nos graus de maturação não maduros e maduros realizada por contagem visual (padrão) e com a utilização do algoritmo proposto para cada seguimento de vídeo utilizado na validação. ....	50
<b>Tabela 3</b> – Resultado da porcentagem de acerto da quantificação realizada com o algoritmo em relação a quantificação visual (padrão). ....	50
<b>Tabela 4</b> – Porcentagem média de acerto resultante da classificação dos frutos de café de acordo com o grau de maturação utilizando o algoritmo proposto.....	51
<b>Tabela 5</b> – Resultado da validação da rede YOLOv7. ....	56

## SUMÁRIO

1.	<b>INTRODUÇÃO.....</b>	14
1.1.	<b>Objetivos.....</b>	16
1.2.	<b>Estrutura da tese.....</b>	16
2.	<b>REFERENCIAL TEÓRICO.....</b>	17
2.1.	<b>Importância socioeconômica do café.....</b>	17
2.2.	<b>Aspectos gerais da cultura do café.....</b>	18
2.3.	<b>Colheita mecanizada de café.....</b>	20
2.4.	<b>Funcionamento da máquina colhedora de café.....</b>	22
2.5.	<b>Visão computacional.....</b>	24
2.5.1.	<b>Espaços de cor.....</b>	25
2.5.2.	<b>Segmentação e classificação.....</b>	26
2.5.3.	<b>Algoritmos de aprendizado de máquina para visão computacional.....</b>	27
2.5.3.1.	<b>YOLO.....</b>	30
3.	<b>MATERIAL E MÉTODOS.....</b>	36
3.1.	<b>Caracterização da área de estudo e máquina colhedora utilizada.....</b>	36
3.2.	<b>Dispositivo para aquisição de imagens.....</b>	37
3.3.	<b>Processamento digital de imagens para classificação de frutos de café.....</b>	38
3.4.	<b>Pré-processamento e anotação de imagens para a rede YOLO v7.....</b>	40
3.5.	<b>YOLO v7 e configurações adotadas.....</b>	41
3.6.	<b>Metodologia e parâmetros para avaliação da classificação.....</b>	44
3.7.	<b>Descrição dos equipamentos e ferramentas utilizadas.....</b>	46
4.	<b>RESULTADOS E DISCUSSÃO.....</b>	47
4.1.	<b>Avaliação do dispositivo para coleta de imagens.....</b>	47
4.2.	<b>Avaliação do algoritmo de processamento digital proposto.....</b>	48
4.3.	<b>Avaliação de desempenho da rede YOLO v7.....</b>	53
5.	<b>CONCLUSÕES.....</b>	61
6.	<b>CONSIDERAÇÕES FINAIS.....</b>	61
7.	<b>REFERÊNCIAS.....</b>	62

## 1. INTRODUÇÃO

O café (*coffea arabica*) é um dos produtos vegetais mais comercializados no mundo. No Brasil, o café tem importância econômica de destaque, com uma produção estimada de 50.380,5 mil sacas de café beneficiado (CONAB, 2022). A área destinada para o cultivo do café arábica é de aproximadamente 80% do total destinado à cafeicultura no país. A valorização do café no mercado internacional reflete em um aumento expressivo do valor das exportações de janeiro a agosto de 2022, o valor é cerca de 5,9 bilhões de dólares e representa um aumento de 54,3% em relação ao mesmo período do ano passado. O estado de Minas Gerais é o maior produtor do país e responde por aproximadamente metade da produção nacional, destacando-se as regiões Sul e Centro-Oeste do estado com produção estimada em 11.751,9 mil sacas de café beneficiado (CONAB, 2022).

A colheita mecanizada do café é uma das operações mais importantes na cafeicultura, podendo corresponder até 40% dos custos totais de produção (SILVA et al., 2013c). Além disso, a colheita é um dos fatores que pode influenciar na qualidade do produto (SILVA et al., 2016). Estudos da interação colhedora/planta têm disponibilizado informações para regulagens ótimas e aprimoramentos da máquina colhedora (FERREIRA JÚNIOR; DA SILVA; FERREIRA, 2016; GOMES et al., 2020; SANTINATO et al., 2014; SILVA et al., 2015; VELLOSO et al., 2020). Diversos fatores relacionados aos cafeeiros podem influenciar no processo de colheita mecanizada como porte, enfolhamento, produtividade e maturação dos frutos (SANTINATO et al., 2014).

As condições de colheita podem variar e exigir diferentes regulagens na máquina colhedora ao longo de um mesmo talhão de café. Silva et al, (2010) observaram diferença significativa entre a força de desprendimento dos frutos em diferentes estádios de maturação e entre diferentes cultivares. Nesse sentido, pesquisadores têm buscado ferramentas para realizar avanços no processo de colheita de café. Estudos desenvolvidos para a conceitual “cafeicultura de precisão” como apresentado por Ferraz et al. (2012), demonstram que a geoestatística é uma importante ferramenta para estudar as relações entre força de desprendimento dos frutos de café. A partir desse trabalho foram desenvolvidos mapas que auxiliam na colheita seletiva. Kazama et al. (2020) também aplicaram geoestatística para gerar mapas para auxiliar a colheita do café. Assim, mapas de prescrição de colheita gerados com dados de produtividade e de maturação dos frutos serviram para gerar zonas, em que para cada zona foi indicado a configuração mais adequada da colhedora. No entanto, para gerar mapas é necessário coletar e georreferenciar informações para processamento antes do processo de colheita, exigindo o

emprego de mão-de-obra e equipamentos específicos. Uma alternativa ao uso de mapas para melhorar o processo de colheita é com a implementação de sensores embarcados na máquina colhedora. Esses sensores podem coletar dados durante o processo de colheita para ajustes da mesma. Ferreira Júnior et al. (2016) instalaram acelerômetros em hastes vibradores de uma máquina colhedora para fazer recomendações para colheita mecanizada do café.

As máquinas colhedoras têm usado sensores para melhorar o processo de colheita, e recentemente tem aumentado o uso de câmeras. Em colhedoras de grãos imagens do produto colhido auxilia no ajuste da colheita, e em alguns modelos de colhedoras de café, câmeras são utilizadas para auxiliar no posicionamento da máquina em relação as linhas de plantio de café. O uso de imagens e técnicas de visão computacional pode beneficiar a atividade agrícola proporcionando sistemas automatizados, não destrutivos e de baixo custo (HAMZA; CHTOUROU, 2018). Estudos recentes aplicando visão computacional, por exemplo, têm demonstrado haver forte correlação entre cor e grau de maturação de frutos de diferentes espécies vegetais (BARGOTI; UNDERWOOD, 2017a; HÄNI; ROY; ISLER, 2020; KAO et al., 2019; KIRK; CIELNIAK; MANGAN, 2020; ZHUANG et al., 2019). Khojasthehnazhand, Mohammadi e Minanei (2019) estimaram o grau de maturação e o volume de frutos de damascos utilizando proporção de cores, Dorj, Lee e Yun (2017) estimaram a produtividade de citrus em pomares na Coreia do Sul.

Em relação aos frutos de café, Ramos et al. (2017) utilizaram a técnica de segmentação de regiões homogêneas baseada em um detector de bordas para realizar a contagem automática de frutos em ramos de café. Ramos, Avendano e Prieto (2018) desenvolveram um método para determinar o grau de amadurecimento dos frutos em ramos da planta de café. Rodríguez et al, (2020) desenvolveram um sistema de visão computacional utilizando rede neural convolucional para detecção automática de frutos de cereja em plantas de café, demonstrando a elevada capacidade de classificação e detecção desde método de aprendizado profundo. Recentemente, Bazame et al. (2021) utilizaram aprendizado profundo para processar imagens georreferenciadas dos frutos de café colhidos, obtidas na colhedora para classificar a maturação dos frutos. Contudo, na cultura no café, poucos estudos foram desenvolvidos com aprendizado profundo, sendo necessário mais trabalhos que forneçam informações para melhorar o processo de coleta de imagens dos frutos e testar algoritmos mais avançados. Essas informações visam contribuir para melhorar o processo de colheita mecanizada de modo a contribuir para o desenvolvimento da cafeicultura.

## **1.1. Objetivos**

A influência do grau de maturação dos frutos de café no processo colheita e na qualidade final do produto é crucial para os produtores. Assim, este trabalho tem como objetivo principal obter imagens de frutos de café durante o processo de colheita mecanizada, e utilizar algoritmos de visão computacional para identificar e classificar o grau de maturação dos frutos de café colhidos em três classes: não maduros, maduros e demasiados maduros.

O objetivo principal é subdividido em objetivos específicos para esclarecer as abordagens e contribuições, assim os objetivos específicos são:

- I. Desenvolver um dispositivo para acoplar na máquina colhedora e coletar imagens dos frutos colhidos durante o processo de colheita;
- II. Desenvolver um algoritmo de visão computacional para identificação e classificação dos frutos;
- III. Aplicar algoritmo de detecção de objetos de última geração para a classificação dos frutos;
- IV. Avaliar e comparar as abordagens propostas com o estado da arte, destacando assim as principais diferenças.

## **1.2. Estrutura da tese**

A tese está dividida em partes que seguem: (i) Referencial teórico abordando os principais tópicos relacionados ao estudo desenvolvido; (ii) Material e métodos apresentando o sistema de aquisição de imagem, o processamento dos dados para aplicar técnicas de visão computacional e a rede YOLOv7 para classificação dos frutos; (iii) Resultados e discussão em que são apresentados os resultados de coleta e processamento de dados, comparando com estudos encontrados na revisão bibliográfica, e (iiii) Considerações finais em que são apresentadas as conclusões a partir do trabalho realizado e futuras linhas de estudos.



## **2. REFERENCIAL TEÓRICO**

### **2.1. Importância socioeconômica do café**

O café é o produto mais comercializado no mundo. Os países Brasil, Vietnã, Colômbia e Indonésia são os maiores produtores de café. Os maiores importadores de café são a União Europeia, Estado Unidos e Japão (INTERNATIONAL COFFEE ORGANIZATION - ICO, 2020). Este produto tem grande importância econômica para o Brasil, além de atrair grandes investimentos no setor agrícola, o país é o segundo maior consumidor de café. Segundo a Associação Brasileira da Indústria de Café – ABIC no ano de 2021 o consumo interno de café chegou a 21,5 milhões de sacas e o consumo per capita foi de 4,84 kg de café torrado em 2021. A procura pela bebida segue em expansão seguindo uma tendência mundial.

Estima-se que para a safra 2022 a área destinada cultivada de café arábica é de 1.816,7 mil hectares e para o café conilon a área cultivada é de 425,3 mil hectares (CONAB, 2022). Segundo a Conab a nacional é estimada em 50.380,5 mil sacas de café beneficiado, sendo Minas Gerais o maior estado produtor com 22.033,1 mil sacas de café beneficiadas. A produção de café arábica para 2022 está estimada em 32.410,2 mil sacas de café beneficiadas e a produção do café conilon está estimada em 17.970,3 mil sacas de café beneficiado. A forte valorização do café no mercado internacional fez com que o valor das exportações de janeiro a agosto de 2022 superasse o valor do mesmo período dos últimos 5 anos, chegando a aproximadamente 5,9 bilhões de dólares (CONAB, 2022).

Os estados do Brasil produtores de café são Minas Gerais, Espírito Santo, São Paulo, Bahia, Rondônia, Paraná, Rio de Janeiro, Goiás, Mato Grosso. O estado de Minas Gerais destaca-se por ser o maior produtor nacional respondendo por metade da produção nacional, com produção estimada em 22.033 mil sacas. Segundo o Censo Agropecuário de 2017 (IBGE, 2017), o estado de Minas Gerais tem o maior número de estabelecimentos destinados a produção de café, são mais de 119 mil estabelecimentos. O segundo estado em número de estabelecimentos é Espírito Santo com pouco mais de 26 mil estabelecimentos.

Diversos fatores podem influenciar o preço do café, primeiramente devido ser uma planta perene o café torna-se um investimento de longo prazo por demandar longo do período do plantio até a produção plena.

A produção do café brasileiro é diversificada devido as mais variadas condições climáticas e de relevo presentes ao longo do território do país. Estes aspectos demonstram uma vantagem para o Brasil pois permite a produção de variados tipos de café e com preços competitivos.

Teixeira et al. (2012) ressalta a cafeicultura no Cerrado brasileiro apresenta modernas práticas fitossanitárias, culturais e nutricionais, além de topografia favorável para mecanização em todas as operações. Já em Minas Gerais na região Sul e na Zona da Mata, a mecanização das etapas de manejo das lavouras reduz conforme a área da propriedade rural destinada a cafeicultura diminui (VILELA; RUFINO, 2010). No entanto o número de propriedades é elevado, permitindo à região alcançar patamares de produtividade e qualidade elevados. Isto implica em um número elevado famílias e, conseqüentemente, de pessoas que tem como fonte de renda atividades relacionadas a produção de café.

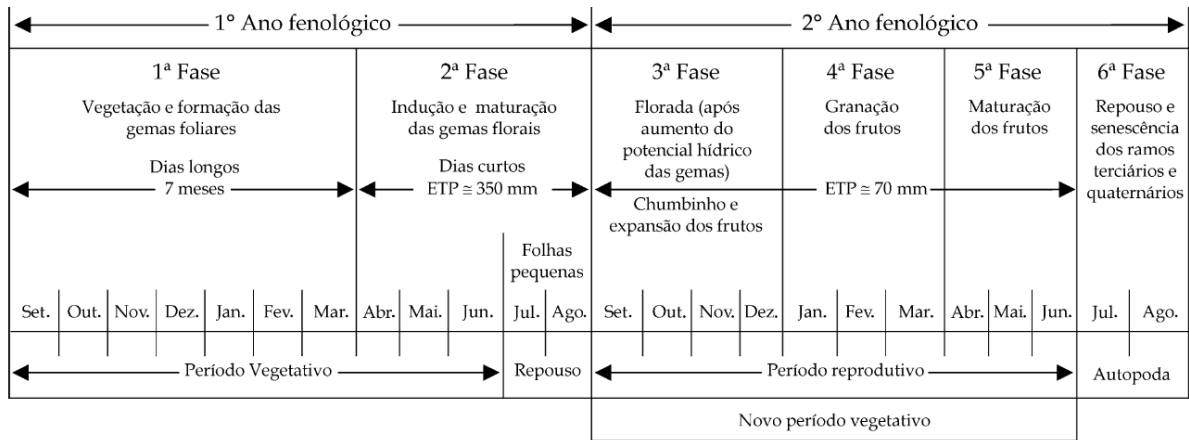
## 2.2. Aspectos gerais da cultura do café

O café é um cultivo perene de porte arbustivo e em lavouras comerciais varia de 2,0 a 4,0 metros de altura, autógama, de raiz pivotante profundo e ramificada nas extremidades próximo a superfície do solo. A planta apresenta ramos ortótopos que crescem vertical e ramos plagiotrópicos com crescimento horizontal. O ciclo produtivo do café é caracterizado pela bienalidade, onde um ano de alta produtividade é seguido por um ano de baixa produtividade (JACINTHO et al., 2017). O produto comercial é a semente e produz frutos do tipo baga.

Dentre as espécies de café destacam-se se *Coffea arabica* L. (Café Arabica) e *Coffea canefora* Pierre (Café Robusta) por serem exploradas comercialmente. O café arábica é nativo de regiões de 1600 m a 2800 m de altitude da Etiópia, onde a temperatura média anual é de 20°C, com chuvas bem distribuídas variando entre 1600 mm e 2000 mm e com a estação do ano seca coincidindo com o período mais frio (DAMATTA; RAMALHO, 2006). Já o café Robusta é oriundo de terras baixas da bacia do rio Congo, em regiões de até 1200 m (DAMATTA; RAMALHO, 2006).

O ciclo fenológico dos cafeeiros da espécie *Coffea arabica* L. possui um período de dois anos para completar. Este ciclo é bem representado pelo fenômeno descrito como bienalidade do café, onde em um ano ocorre alta produtividade e é seguido de um ano de baixa produtividade, em que a produtividade é reduzida para o melhor desenvolvimento da planta (LIMA et al., 2016). De Camargo e De Camargo (2001) sugeriram que no ciclo de dois anos de produtividade as plantas passam por seis fases distintas conforme apresentado na Figura 1.

**Figura 1** – Ciclo fenológico bianual do cafeeiro arábica nas condições climáticas tropicais do Brasil.



Fonte: Imagem reproduzida de De Camargo e De Camargo (2001).

Um aspecto importante a ser observado no ciclo fenológico é a floração do cafeeiro. Sendo caracterizada como 3ª fase do ciclo e podendo ocorrer nos meses de setembro a dezembro (Figura 1). A florada é altamente influenciada pelo regime hídrico, Miranda, Drumond e Ronchi (2020) associaram o efeito de diferentes níveis de déficit hídrico ao estágio de desenvolvimento do broto da flor e concluíram que o déficit hídrico contribuiu para a concentração da floração, sendo que a suspensão da irrigação promoveu uma sincronização satisfatória da maturação dos frutos. O resultado de uma floração não uniforme é uma maturação dos frutos também não uniforme, implicando diretamente no planejamento operacional da colheita. Silva et al. (2009) explanaram que a desuniformidade de maturação dos frutos interfere na escolha do momento ideal para iniciar a colheita e na qualidade final do produto, devido a presença de frutos não maduros, compondo uma das limitações da operação de colheita.

Entender o desenvolvimento fenológico da cultura é essencial para o planejamento da atividade agrícola. Este ciclo está relacionado com o clima e a fase da cultura que juntos vão determinar o planejamento e execução das operações de manejo e colheita da lavoura cafeeira. Além disso, o sistema de produção pode ser mecanizado ou não influenciando em aspectos tais como topografia e espaçamento da cultura. Pereira et al. (2011) analisaram o crescimento, produtividade e a bienalidade do cafeeiro em diferentes espaçamentos, os autores concluíram que a redução no espaçamento entre as linhas e entre as plantas resultou em aumento de produtividade. Cunha et al. (2016) destacam que o uso da mecanização proporciona maior eficiência das operações e assim permite a viabilidade econômica do cultivo de café que dentre outros fatores, depende principalmente da redução de custos.

### 2.3. Colheita mecanizada de café

A mecanização é uma das grandes ferramentas do produtor para a redução de custos de produção ao elevar a velocidade em que as operações são realizadas. Especialmente na operação de colheita do café onde a velocidade da operação influencia a qualidade do produto final e na redução de perdas (SILVA et al., 2009). Tavares et al. (2019) observaram que a capacidade operacional da colheita mecanizada de café é muito elevada ao comparar com as operações de colheita semimecanizadas e manuais, mesmo que a colheita mecanizada exija a operação de varredura após a passada da colhedora.

Ao estudar a viabilidade econômico-financeira da cafeicultura no sul de Minas Gerais, Lanna e Reis (2012) observaram que a colheita mecanizada apresenta um impacto significativo na composição das despesas. Os menores custos que resultam em indicadores econômico-financeiros melhores quando comparados a opção de colheita manual. Os autores ainda destacam que o preço do café tem uma influência de destaque na viabilidade econômica do empreendimento. Cunha et al. (2016) analisou os sistemas de colheita mecanizados de café utilizando colhedora automotriz e tracionada, e observaram redução de custos operacionais de até 61% em relação a colheita manual.

Existem diversos fatores que podem influenciar na operação de colheita mecanizada. Santinato et al. (2014) destacaram que o máximo de eficiência operacional da colheita pode minimizar a necessidade de repasse manual e reduzindo os custos. Os autores apontam que para atingir máxima eficiência é necessário a correta regulagem em relação as hastes de vibração e velocidade de trabalho da máquina conforme fatores da planta como: variedade, porte, enfolhamento, produtividade e o estágio de maturação dos frutos.

Diversos pesquisadores buscaram melhor entender os fatores que afetam a colheita mecanizada. Um destes fatores é o grau de maturação dos frutos. Silva et al. (2009) avaliaram a influência de um maturador fisiológico na colheita mecanizada e seletiva do café, sendo observado que a utilização do maturador elevou-se o volume de frutos colhidos e a porcentagem de frutos cereja, na primeira e segunda passada da colhedora.

Outro fator que influencia na colheita mecanizada do café é a produtividade. Santinato et al. (2015) avaliaram a colheita mecanizada de café empregando repetidas operações da colhedora em plantas com diferentes cargas de frutos. Os autores concluíram que em lavouras de cargas altas (121,54 sacas de café beneficiado ha<sup>-1</sup>), duas a três passadas da colhedora são suficientes para dispensar a necessidade de repasse manual e, em lavoura de carga intermediária (50,78 sacas de café beneficiado ha<sup>-1</sup>), duas passadas da colhedora são suficientes. Em estudo

para avaliar a influência morfológica e produtiva da colheita no cafeeiro, Santinato et al. (2019a) observaram que independentemente da carga de frutos das plantas, a colheita manual pode ser substituída pela colheita mecânica utilizando até duas passadas sem causar maiores danos às plantas. Além disso, os autores afirmam que lavouras com cargas maiores apresentam maior desfolhamento que lavouras com cargas intermediárias e o café possui capacidade de desfolhamento de uma safra para outra.

A influência da declividade na colheita mecanizada também já foi avaliada. Santinato et al. (2016) avaliando o tempo e movimentos da colheita mecanizada em diferentes declividades, observaram que em áreas onde a declividade é mais acentuada, de 20% ou a mais, a operação de colheita demandou 21,6% a mais de tempo para realizada quando comparada com declividades menores. A utilização de microterraços é uma opção para realizar a colheita mecanizada em áreas com declividades muito acentuadas. Tavares et al. (2019) comparam a colheita mecanizada em microterraços com as colheitas semimecanizada e manual, os resultados demonstraram uma elevada capacidade operacional da colheita mecanizada unilateral. Além disso os autores destacam que a colheita mecanizada causa menor desfolhamento nas plantas reduzindo perdas futuras na produção.

Visando melhorar o gerenciamento operacional da colheita, diversos estudos foram realizados buscando entender ou controlar alguns dos fatores da planta que influenciam na colheita mecanizada do café. Ferraz et al. (2012) utilizaram geoestatística para estudar as relações entre força de desprendimento dos frutos e produtividade, os resultados demonstraram uma relação inversamente proporcional das variáveis estudadas. Silva et al. (2013a) avaliaram a eficiência de colheita mecanizada em função da força de desprendimento dos frutos de café, concluindo que este é um bom parâmetro para indicar o início da colheita e o gerenciamento desta operação. Barros et al. (2018) desenvolveram um classificador capaz de diferenciar frutos de café não maduros de frutos maduros com base na força de desprendimento, e assim determinar o momento adequado para iniciar a colheita mecanizada. Kazama et al. (2020) geraram zonas de manejo com dados de produtividade e maturação dos frutos para indicar configurações da colhedora mais adequadas em cada zona.

Embora muitos produtores utilizem a colheita manual nas primeiras safras da lavoura de café, Santinato et al. (2019b) analisou o custo da colheita mecanizada de café da primeira safra usando colhedoras próprias ou alugadas em repetidas operações. Os resultados demonstraram a redução de custo que pode variar de 24 a 60% com menos danos e aumentando a eficiência na operação, ainda sendo possível com adaptações na colhedora eliminar a utilização da colheita manual. Estes resultados corroboram com os de Silva et al. (2013b) que

avaliaram e compararam com a colheita manual o desempenho da colheita mecanizada a partir da segunda safra bem como os efeitos sobre a produtividade de café nas safras subsequentes. Foi observado a tendência de aumento de produtividade quando colhidos mecanicamente, sendo este significativo na quarta safra e superior a 20% quando comparado com a colheita manual.

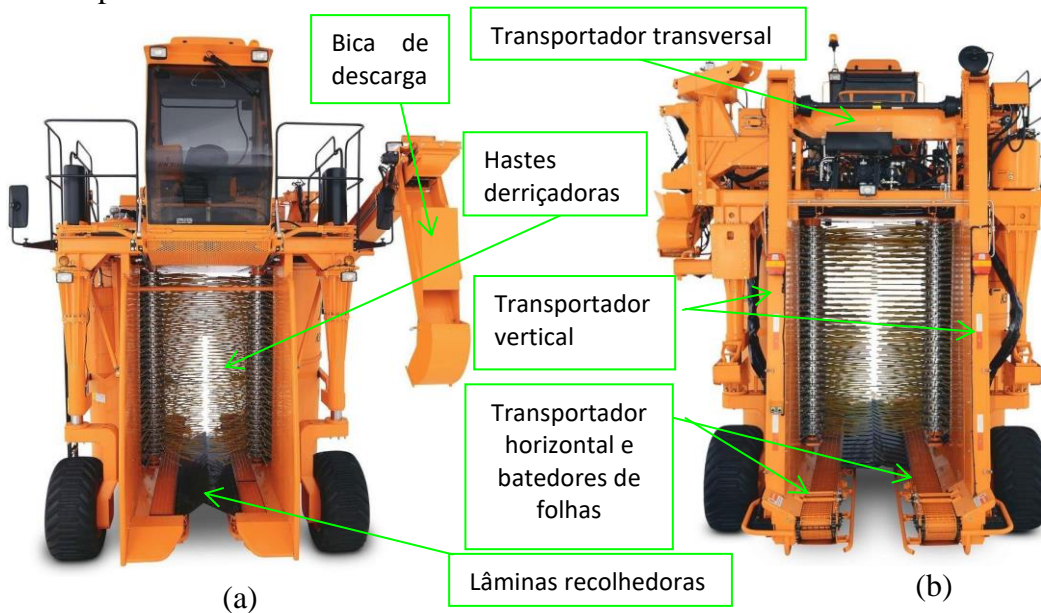
Para a colheita seletiva também é possível distribuir e posicionar as hastes derriçadoras direcionando a derriça onde há maior quantidade de frutos e/ou mais maduros. Silva et al. (2010) observaram diferença significativa entre a força de desprendimento dos frutos em diferentes estádios de maturação e entre diferentes cultivares. Diversos fatores relacionados à planta de café podem influenciar o processo de colheita mecanizada. Ferreira Junior et al. (2018) aponta que a colheita mecânica seletiva de café favorece o processo de pós-colheita, proporcionando lotes mais homogêneos em relação à maturação dos frutos.

De maneira geral, diversos estudos realizados buscaram melhorar a eficiência da operação e também visaram a realização da colheita somente dos frutos com o grau de maturação adequado para obter o melhor produto final possível. Outros estudos buscaram caracterizar as faixas de interação dinâmica de frequências para aprimorar a colheita seletiva (COELHO et al., 2016; FERREIRA JÚNIOR et al., 2020; VILLIBOR et al., 2016). Sartori et al. (2002) instalaram um sonar e monitor para medir um volume de café durante um determinado período de tempo, sendo que este procedimento possibilita a mensuração para gerar mapas de produtividade.

#### **2.4. Funcionamento da máquina colhedora de café**

A máquina colhedora de café pode ser automotriz ou tracionada por um trator. Existem diversos fabricantes de máquinas colhedoras de café. De maneira geral, o funcionamento da máquina é semelhante para todos os fabricantes com algumas modificações. A Figura 2 apresenta um modelo comercial de máquina colhedora de café em que são anotados os principais equipamentos do processo de colheita mecanizado.

**Figura 2** – Imagem de uma colhedora de café. (a) Colhedora de café vista frontal e (b) vista da parte traseira.



Fonte: Imagem adaptada de Máquinas Agrícolas Jacto S.A. (2022).

A máquina colhedora realiza diversas etapas durante o processo de colheita. As hastes derrçadoras acopladas em cilindros oscilantes verticais (Figura 2a) envolvem lateralmente as plantas de café para realizar a derrça dos frutos (SILVA et al., 2013a). A derrça dos frutos de café ocorre devido ao impacto e a transferência de energia vibracional para os frutos (GOMES et al., 2020). Os frutos derrçados caem em lâminas recolhedoras e são direcionados para as esteiras onde são transportados horizontalmente até elevadores (Figura 2b). Ainda nas esteiras, é realizada a primeira etapa do processo de limpeza, separando os frutos derrçados das folhas que também caem com a execução da derrça. Batedores localizados no final do percurso das esteiras auxiliam na separação de frutos e folhas. O transporte vertical dos frutos é realizado nos elevadores (Figura 2b), que elevam os frutos até uma esteira transversal. Antes da chegada à esteira transversal, os frutos passam pela última etapa do processo de limpeza que é realizada por ventiladores que atuam como exaustores retirando impurezas dos frutos. Os frutos então podem ser transportados para o tanque graneleiro da máquina colhedora ou transportados pelo sistema de descarrega (Figura 2a) diretamente em carretos auxiliares tracionados por tratores.

Geralmente são realizados três ajustes na colhedora para o processo colheita: vibração das hastes derrçadoras, velocidade de deslocamento e o torque exercido pelas molas da correia de freio (KAZAMA et al., 2020). A vibração das hastes e a velocidade de deslocamento pode ser alterada pelo operado da máquina colhedora durante o processo de colheita. O ajuste do torque exercido pelas molas da correia de freio deve ser realizado com a máquina parada e com o sistema de vibração desligado. O ajuste é independente para cada um dos cilindros em que as

hastes derriçadoras são acopladas. Alguns modelos de colhedoras possuem motor hidráulico para ajuste desse torque.


## **2.5. Visão computacional**

O desenvolvimento de técnicas de processamento de imagens tem uma vasta aplicação em máquinas e implementos agrícolas e vêm sendo exploradas para automatizar ou aperfeiçoar diversos processos ao longo da cadeia produtiva. Estas aplicações vão desde a criação de veículos autônomos (BECHAR; VIGNEAULT, 2016), máquinas para cultivo (ZAIDNER; SHAPIRO, 2016), algoritmos para identificação de plantas (MEYER; NETO, 2008) e identificação de doença de plantas (CHEN et al., 2020), estimativa de produtividade antes da operação de colheita (BARGOTI; UNDERWOOD, 2017b; KOIRALA et al., 2019) ou durante a colheita (CHINCHULUUN; LEE; EHSANI, 2007), desenvolvimento de robôs para realização da colheita autônoma (KANG; ZHOU; CHEN, 2020) e também para aprimorar operações de pós-colheita (PINTO et al., 2017).

Uma das maiores dificuldade em desenvolver sistemas para detecção de frutas é devido à variação nos aspectos exteriores dos frutos como nas propriedades de cor, forma, tamanho e textura. Existem frutos que podem apresentar cores semelhantes às folhas, ainda podendo ter suas cores alteradas por variações na iluminação (LIN et al., 2020). Estas dificuldades são mais pronunciadas nas condições de campo, já para sistemas embarcados em máquinas implica diretamente no design do projeto que deve conceber a coleta de imagens de maneira a proporcionar um ambiente mais uniforme possível. Chinchuluun, Lee e Ehsani (2007) desenvolveram um sistema de monitoramento de produtividade de laranja baseado em visão de máquina. Neste sistema a coleta de imagens foi realizada em um compartimento fechado que abrigava a câmera e as lâmpadas (Figura 3b). A câmera e as lâmpadas ficavam em uma distância determinada dos frutos visando obter melhor qualidade de imagem e com iluminação apropriada, também foram instalados filtros polarizados em cada lâmpada para evitar brilho nos frutos.



**Figura 3** – Imagem de dispositivo para coleta de imagens de laranjas colhidas. a) Câmera e lâmpadas. b) Sistema de coleta de imagens instalada na bancada de testes.



(a)



(b)

Fonte: Imagem adaptada de Chinchuluun, Lee e Ehsani (2007).

Após a coleta de imagens, técnicas de processamento digital de imagens são aplicadas com o objetivo de "ensinar" um computador a entender as características de uma imagem (RODRÍGUEZ-PULIDO et al., 2012). Um sistema de visão computacional pode ser implementado para detectar a cor, detectar defeitos e estimar dimensões dos frutos de maneira não destrutiva e não invasiva. Para isto, é necessário conhecer aspectos e características das imagens, bem como as técnicas existentes para o processamento destas informações.

### 2.5.1. Espaços de cor

As imagens digitais são representadas por uma combinação de um ou mais canais de cor que formam a cor usada na imagem. De acordo com Garcia-Lamont et al. (2018), os espaços de cor utilizados mais na literatura são o RGB (do inglês *red*, *green* e *blue* – vermelho, verde e azul), HSV (do inglês *hue*, *saturation* e *value* – matiz, saturação e valor), HSI (do inglês *hue*, *saturation* e *intensity* - matiz, saturação e intensidade),  $L^*a^*b$ ,  $L^*u^*v$ , YUV e YCbCr.

O espaço RGB é o mais utilizado para representação de imagens digitais, é baseado na porção do espaço eletromagnético visível aos olhos humanos (faixa aproximada de 400-700 nm). Garcia-Lamont et al. (2018) concluíram que apesar do espaço RGB ser o mais amplamente utilizado, não é o mais recomendado. Neste espaço de cor não é possível utilizar a distância euclidiana devido as alterações de cores no espaço não serem lineares.

O espaço HSV é representado pelo matiz ou tonalidade (H) sendo o comprimento de onda dominante na cor, a saturação (S) é a “pureza” da cor ou como a matiz é diluída na luz branca e o valor (V) é a luminância da cor (SOLOMON; BREACKON, 2013). Neste espaço de cor a intensidade é dissociada do matiz, ou seja, os componentes de cores são independentes do

brilho. O espaço de cor HSI é similar ao HSV, para ambos matiz e saturação são empregados para representar cores, exceto o brilho que é diferente.

O modelo padrão XYZ desenvolvido pela Comissão Internacional de Iluminação (*Commission Internationale d'eclairage*) é um dos mais empregados para reproduzir as cores independentemente dos dispositivos de exibição (GARCIA-LAMONT et al., 2018). Este modelo é composto por três cores básicas X, Y e Z de forma que podem descrever todas as cores. Existem diversas variações deste modelo que são aplicadas no processamento de imagem. Um deles é o espaço  $L^*a^*b$  o qual lineariza as mudanças de tonalidades. Este espaço de cor é similar ao HSV e HSI, e tendo como vantagem a possibilidade de utilizar a distância euclidiana para computar as diferenças de cromaticidade devido as mudanças de tonalidades serem lineares. Já os espaços de cores YCbCr e YUV apresentam três componentes que são a luminância e os outros componentes de cromaticidade, YCbCr é mais utilizada para compressão de imagens (GARCIA-LAMONT et al., 2018).

Existem diversas aplicações de espaços de cores para a classificação de frutos. Para a segmentação de amoras, Azarmdel et al. (2020) testaram para cada um dos canais RGB para realizar a segmentação utilizando o método de limiar Otsu e observaram nos resultados que utilizando o canal azul (B) foi possível segmentar todos os frutos. Lopez, Cobos e Aguilera (2011) utilizaram os espaços RGB e HSV para testar o sistema de classificação de falhas em citrus. Os autores observaram que os resultados com o espaço de cor HSV foram um pouco melhores. Desta forma, os espaços de cores devem ser testados para as situações do experimento, com o intuito de escolher aquele que oferece o melhor resultado para as condições em que é empregado.

### **2.5.2. Segmentação e classificação**

Segmentação é o processo de subdividir uma imagem em sub-regiões. A correta segmentação vai depender do tipo do objeto e da região que se deseja identificar (SOLOMON; BREACKON, 2013). Sendo um dos principais desafios da visão computacional, este processo determina a qualidade do sistema de reconhecimento de padrões e pode ser melhorado com a utilização de pré-processamento de imagem (GARCIA-LAMONT et al., 2018). O pré-processamento de imagem pode consistir em conversão de espaço de cor, filtragem para remoção de ruídos da imagem ou para realce atributos.

Existem diversos métodos de segmentação baseados em limiar, um dos métodos mais rápidos de segmentação e que exige pouco do computador é o limiar global. A determinação de

um limiar ótimo pode ser um processo iterativo, em processos que exigem total automação utiliza-se o limiar adaptativo (GARCIA-LAMONT et al., 2018).

Um dos métodos de segmentação mais utilizada e de grande importância é método de segmentação de Otsu. Este processo minimiza as variâncias intraclases e converte a imagem inicial em primeiro plano e plano de fundo, comparando a intensidade dos pixels e o número de pixels (AZARMDEL et al., 2020). Mazne e Nashat (2019) desenvolveram um sistema para a classificação do estágio de maturação de banana, aplicando a técnica de segmentação de Otsu para segmentar imagens digitais de bananas e realizar sua classificação conforme o grau de maturação. O método de Otsu e outros métodos como o de Kapur, podem ser expandidos para segmentação de limiar multiníveis, no entanto, isto irá exigir maior tempo de processamento do computador.

A segmentação também pode ser realizada utilizando métodos baseados em região. Nestes métodos critérios de similaridade predefinidos são utilizados para realizar agrupamentos de pixels em regiões maiores (GARCIA-LAMONT et al., 2018). Para realizar a contagem automática de frutos em galhos de café Ramos et al. (2017) utilizaram a técnica de segmentação de regiões homogêneas é baseada em um detector de bordas com caráter dinâmico. Esta operação foi realizada com diferentes operações morfológicas baseadas na detecção de bordas. Após a segmentação de regiões homogêneas, o processamento consiste em destacar os contornos resultantes para avaliar quais pertencem aos frutos de café. Em outro estudo de Ramos, Avendano e Prieto (2018) desenvolveram um método para determinar o grau de amadurecimento dos frutos em ramos da planta de café. Neste método os autores desenvolveram um algoritmo para processamento de imagens e classificar os frutos em não maduro, semi-maduro e maduro.

### **2.5.3. Algoritmos de aprendizado de máquina para visão computacional**

O bom emprego de redes neurais em processamento de imagens implica em diversas vantagens, seu uso é apropriado para aplicação em tempo real devido ao menor tempo de processamento da máquina e maior robustez, além de possibilitar a contabilização de informações espaciais (GARCIA-LAMONT et al., 2018). Essa técnica de aprendizado de máquinas vem sendo aplicada em diversos estudos para detectar, classificar e estimar frutos e/ou seus parâmetros.

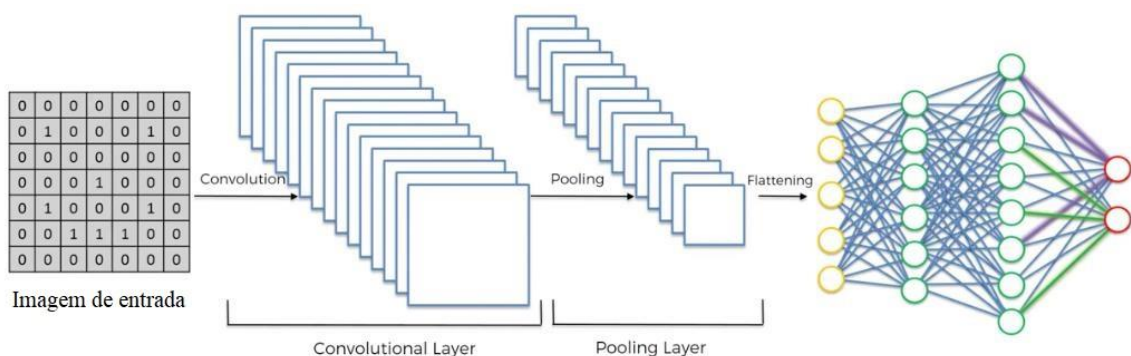
As redes neurais são compostas por uma simples estrutura chamada de neurônio ou nódulo, ao se unir com outros neurônios forma uma estrutura complexa capaz de executar processamentos simples ou complexos (AZARMDEL et al., 2020). Nas camadas de neurônios

ocorre a modificação dos dados segundo uma função de transferência, esta função pode ser a sigmoide, senoide, linear, etc. Os neurônios de uma camada estão interligados com os neurônios da camada subsequente.

Semelhante à técnica de redes neurais, a técnica de Redes Neurais Convolucionais - RNC (do inglês *Convolutional Neural Network* – CNN) também pertence ao campo computacional de aprendizado de máquina. Esse modelo tem sido amplamente utilizado para extração de características de imagens. Em 2012 a rede AlexNet ganhou notoriedade ao vencer uma competição de classificação de imagem, a ILSVRC (do inglês *ImageNet Large Scale Visual Recognition Challenge*). Desde então, o uso de RNC no processamento de imagens vem se destacando devido ao aumento da performance em aplicações, permitindo a utilização de modelos compostos por várias camadas de processamento (PINTO et al., 2017). Kamilaris e Prenafeta-Boldú (2018) realizaram um estudo de revisão sobre o uso de aprendizado profundo (do inglês *deep learning*) na agricultura e observaram que está técnica proporciona melhores resultados em relação a acurácia de detecção no processamento de imagem comparado com técnicas anteriores.

Redes neurais convolucionais fornecem uma representação hierárquica dos dados por meio de várias convoluções e utilizam imagens diretamente como entrada. O treinamento de RNC necessita de uma imagem de entrada e um rótulo associado, a RNC faz a extração de características automaticamente e é composta de quatro etapas principais: Convolução, *Pooling*, Achatamento (do inglês *Flattening*) e Conexão Completa (do inglês *Full Connection*) conforme a Figura 4.

**Figura 4** – Exemplo de uma estrutura de rede neural convolucional.



Fonte: Imagem adaptada de Naik e Patel (2017).

Na etapa de convolução, um o detector de recursos é aplicado na imagem de entrada para criar o mapa de características (do inglês *feature map*), onde alguns dos detectores básicos são *Sharpen*, *Edge Detect*, *Edge Enhance*, *Median* e *Emboss*. Nesta etapa são utilizadas as

funções de ativação para quebrar a linearidade da imagem, podendo ser utilizada a função Relu ou outras funções como Sigmoid ou Leaky ReLU se necessário (NAIK; PATEL, 2017).

Na etapa *Pooling*, os mapas de características são utilizados como dados de entrada para realizar o mapeamento de certas características necessários das imagens (NAIK; PATEL, 2017) e assim as informações da camada anterior são simplificadas. As funções da etapa *Pooling* podem ser de mínimo, máximo ou mediana, uma vez que o objeto que se deseja reconhecer ou classificar pode variar em características.

Na etapa de achatamento simplesmente ocorre a conversão do mapa de características da etapa anterior em um único vetor, que será utilizado como dado de entrada na rede neural. O último passo é a conexão completa, sendo a implementação de uma rede neural artificial em que todos os nós de entrada, ocultos e de saída são conectados (NAIK; PATEL, 2017).

Estudos recentes têm utilizado redes neurais convolucionais para detectar e classificar diversos tipos de frutos. O processo de detecção pode ser realizado em dois estágios, em que primeiramente é realiza a extração de características seguida da classificação e/ou localização ou pode ser realizada em apenas um estágio dependendo do modelo utilizado. Os modelos mais conhecidos que processam em dois estágios são as redes neurais convolucionais baseadas em região (do inglês *Region based convolutional neural networks* - RCNN), *Fast-RCNN* e *Faster-RCNN* (DIWAN; ANIRUDH; TEMBHURNE, 2023). Já o modelo mais amplamente utilizado de processamento em um estágio é a rede YOLO que será abordado no próximo tópico.

Estudos de revisão têm apontado que a utilização de aprendizado profundo, campo computacional em que redes neurais convolucionais faz parte, possibilitou uma classificação mais rápida e com maior acurácia. Kamilaris e Prenafeta-Boldú (2018) realizaram uma revisão sobre aprendizado profundo em agricultura e observaram que a maioria das técnicas de processamento de imagem popularmente utilizadas apresentaram desempenho inferior quando comparadas as técnicas de aprendizado profundo. Resultados similares foram observados por (KOIRALA et al., 2019), apontando que em breve haverá muitos trabalhos sobre a adoção de uma estrutura de aprendizado profundo para aplicações de agricultura de precisão.

Dentre as aplicações na agricultura de RNC podemos citar o estudo de Zabawa et al. (2020). Nesse estudo foi desenvolvido um sistema para contagem de bagas de videira em imagens via segmentação semântica usando redes neurais convolucionais. Para isso utilizaram câmeras de qualidade DLSR montadas em uma plataforma de fenotipagem de campo com vários sensores. Para o processamento utilizaram a combinação de codificador e decodificador que resulta em uma rede de segmentação semântica totalmente convolucional. Os autores foram

capazes de obter acurácia de 98,79% e 97,15% para duas espessuras de bordas diferentes, respectivamente.

Pinto et al. (2017) utilizaram redes neurais convolucionais profundas em uma aplicação na pós colheita de café, em que foi desenvolvido um sistema para estimar a probabilidade de diferentes defeitos de café em ambiente controlado utilizando. Os autores observaram que a acurácia do sistema variou conforme o defeito analisado, o maior valor de acurácia foi 98,75% para grãos escuros e a menor acurácia para grãos quebrados. Foi apontado que a baixa acurácia pode ter sido resultado de insuficiência de dados, ou seja, um banco de dados pequeno.

Kazama (2019) utilizou a rede Fast R-CNN em imagens dos frutos em plantas de café para realizar a identificação e classificação desses frutos conforme os estádios de maturação. Os pontos onde foi realizada a coleta das imagens foram georreferenciados para confecção de mapas de prescrição de produtividade e maturação visando a colheita seletiva do café. Considerando a contagem total dos frutos de cada imagem foi obtido  $R^2$  de 0,92.

### 2.5.3.1. YOLO

A rede YOLO (do inglês *You Only Look Once*) é um algoritmo detector de objetos de um estágio desenvolvido por Redmon et al. (2015). Esse nome foi dado ao algoritmo pois identifica objetos e seu posicionamento olhando para a imagem apenas uma vez. O algoritmo tem sido amplamente utilizado devido sua agilidade de processamento e acurácia.

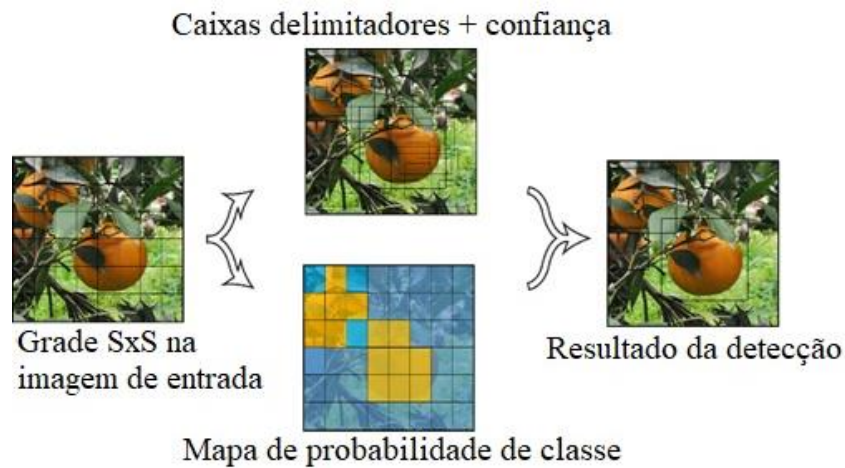
A rede YOLO realiza a detecção de objetos como um problema de regressão em vez de um problema de classificação. Assim, a detecção de objetos é realizada separando a imagem em  $N$  células de uma grade  $S \times S$ . Cada célula da grade pode conter o objeto e este será detectado se estiver no centro dela. As caixas delimitadoras que demarcam onde o objeto está localizado na imagem são previstas com base nos valores de confiança e ponderadas com as probabilidades previstas. As caixas delimitadoras são compostas por cinco valores:  $x$ ,  $y$ , largura, altura e confiança. Os valores de confiança são o indicativo se a caixa possui ou não o objeto. A confiança é definida utilizando a Equação (1).

$$C_{ij} = Pr \times (\text{objeto}) \times IOU_{verdpred} \quad (1)$$

Em que  $C_{ij}$  representa a confiança da  $j$ -ésima caixa delimitadora na  $i$ -ésima célula da grade,  $IOU_{verdpred}$  indica a coincidência entre a referência e a caixa delimitadora prevista. A função IoU é utilizada para escolher a caixa delimitadora adequada. Além disso, o YOLO utiliza a função NMS (do inglês *Non-Maximum Suppression*) para remover o excesso de caixas

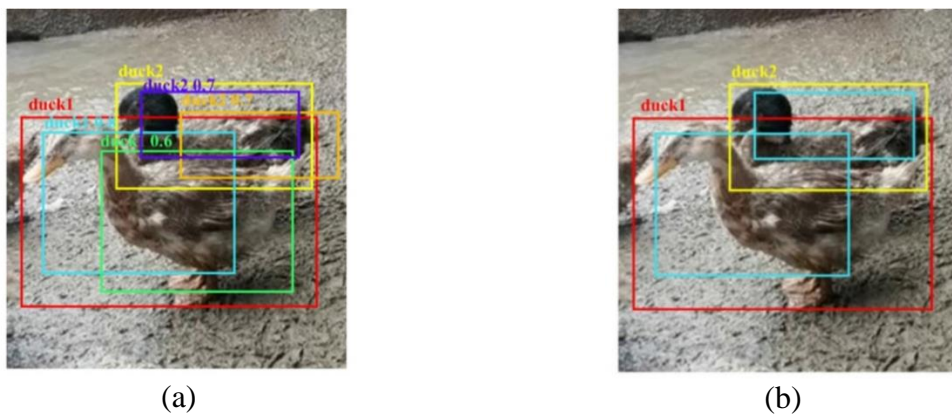
delimitadoras. A Figura 5 apresenta um exemplo de como a rede YOLO funciona e a Figura 6 apresenta efeito da função NMS.

**Figura 5** – Processo de detecção de rede YOLO.



Fonte: Imagem adaptada de Chen et al. (2022a).

**Figura 6** – (a) Simulação de caixas delimitadoras previstas pela rede. (b) Remoção das caixas delimitadoras redundantes após a ação da função NMS.



Fonte: Imagem adaptada de Jiang et al. (2022).

Alguns algoritmos de detecção em um estágio incluem YOLO (REDMON et al., 2016), YOLOV3 (REDMON; FARHADI, 2018), YOLOV4 (BOCHKOVSKIY; WANG; LIAO, 2020), YOLOV5, SSD (LIU; ANGUELOV, 2016), RetinaNet (LIN et al., 2017) e recentemente YOLOv7 (WANG; BOCHKOVSKIY; LIAO, 2022).

Os diferentes modelos de YOLO têm sido utilizados para enfrentar diversos desafios na agricultura. Santana et al. (2023) utilizaram um algoritmo baseado na rede YOLOv3 e OpenCV para realizar a identificação e contagem de plantas de café. O algoritmo obteve acurácia de 96,8% na contagem de plantas com 6 meses de desenvolvimento. Bazame et al. (2022) testaram 4 modelos da rede YOLO para classificar frutos de café nas plantas, a rede YOLOv4 apresentou

maior valor de mAP quando comparado com as redes YOLOv4-tiny, YOLOv3 e YOLOv3-tiny. Chen et al. (2022b) fizeram modificações na rede YOLOv4 para realizar a classificação de citrus em pomar. Os resultados foram comparados com outros modelos sendo que o modelo melhorado de YOLOv4 e o modelo original obtiveram melhores resultados quando comparados com os classificadores SSD, YOLOv3, Detectron2 e Faster RCNN. As redes YOLOv4 melhorada pelos autores e a rede YOLOv4 obtiveram acurácia de 92,9% e 96%, respectivamente.


Em estudo de (PÉREZ-PORRAS et al., 2022) foram utilizados diferentes modelos de YOLO para detecção de plantas daninhas. O modelo YOLOv5 obteve valores de F1-score de 72,1% a 65,3%, sendo esses maiores quando comparados com os valores obtidos com diferentes modelos de YOLOv3 e YOLOv4 que obtiveram valores entre 70% a 70,8%. Recentemente, o modelo YOLOv7 foi publicado por Wang, Bochkovskiy e Liao (2022) com algumas modificações que permitem melhores resultados quando comparado com outros detectores de objeto.

O YOLOv7 foca na otimização treinamento da rede para melhorar a precisão sem aumentar o consumo de parâmetros computacionais, podendo reduzir o esforço computacional em 50% quando comparado com outros modelos de detecção de objetos avançados (QIU et al., 2023). Essa versão difere das anteriores pela utilização dos módulos ELAN, na estratégia de reparametrização e uma estrutura de pirâmide de característica (HUSSAIN et al., 2022). Assim, diversos estudos têm utilizado a rede YOLOv7 na agricultura: para a detecção de citrus (CHEN et al., 2022a), botão de flor de maçã (YUAN, 2023), abacaxi (LAI et al., 2023) e patos (JIANG et al., 2022). Portanto, com base nos recentes avanços encontrados na literatura, nesse estudo o modelo YOLOv7 foi escolhido como a rede para o desenvolvimento do classificador de maturação de frutos de café.

Na Figura 7 é apresentado uma comparação de desempenho da rede YOLOv7 com outros modelos de última geração em detecção de objetos. Na Tabela 1 está resumido as publicações selecionadas nos últimos 5 anos que serviram de base para este estudo.



**Figura 7** – Utilizando o banco de dados MS COCO o gráfico apresenta a comparação de desempenho do modelo YOLOv7 em relação a outros detectores de objetos em tempo real.



Fonte: Imagem reproduzida de Wang, Bochkovskiy e Liao (2022).

**Tabela 1** – Lista de publicações selecionadas (2018-2023) como base de referência para o desenvolvimento deste estudo.

Referência	Modelo/técnica	Aplicação	Métricas
(WAN et al., 2018)	Visão computacional e classificação com BPNN.	Detecção e maturação de tomates.	Acurácia de 99,3%.
(HAMZA; CHTOUROU, 2018)	Visão computacional e ANN.	Maturação de maçãs.	Acurácia de 92,5% a 96,6%.
(RAMOS; AVENDAÑO; PRIETO, 2018)	Reconstrução por nuvem de pontos e classificação com SVM.	Maturação de café em ramos das plantas.	R <sup>2</sup> de 0,63 a 0,97.
(KAO et al., 2019)	Autoencoders convolucionais.	Maturação de tomate.	Acurácia de 100%.

Tabela1 – Continuação.

Referência	Modelo/técnica	Aplicação	Métricas
(KAZAMA, 2019)	Fast RCNN	Maturação de frutos de café em ramos da planta.	R <sup>2</sup> de 0,92.
(ZHUANG et al., 2019)	Segmentação, região de interesse e classificação com aprendizado de máquinas (NB, LDA e SVM).	Maturação de banana.	Acurácia de identificação geral de 99,2%, 100% e 99,2%.
(KHOJASTEHNAZHAND; MOHAMMADI; MINAEI, 2019)	Processamento digital de imagens e classificação com LDA e QDA.	Maturação e estimação de volume de damasco.	Acurácia de 90,4% e 92,3%.
(ZABAWA et al., 2020)	Segmentação semântica e Mark-RCNN.	Detecção e contagem de bagas de videira.	Acurácia de 94% e 85,6%.; 81,5% e 74,3%.
(LIN et al., 2020)	Método baseado em profundidade, cor e forma.	Detecção de pimenta, berinjela e goiaba.	Precisão de 86,4%, 88,6% e 88,8%.
(HÄNI; ROY; ISLER, 2020)	Método supervisionado com base em Modelos de Mistura Gaussiana e aprendizado profundo.	Detecção e contagem de maçã pomares.	Acurácia de 95,6% a 97,8%.
(MAO et al., 2020)	MT-CNN combinado com componente de cor e SVM.	Detecção de pepino.	Taxa de reconhecimento de 90%.
(KIRK; CIELNIAK; MANGAN, 2020)	Detecção utilizando a combinação de recursos bio-inspirados com CNN de um estágio.	Detecção de morango.	F1-score de 74%.
(AZARMDEL et al., 2020)	Segmentação e classificação com ANN e SVM.	Maturação de amora.	Acurácia de 98,3% a 100%.
(MIRAEI ASHTIANI et al., 2021)	Os modelos de CNN: DenseNet, Inception-v3, ResNet-18, ResNet-50 e AlexNet.	Maturação de amoras.	Acurácia de 94,8% a 98,3%.

Tabela1 – Continuação.

Referência	Modelo/técnica	Aplicação	Métricas
(BAZAME et al., 2021)	YOLOv3-tiny.	Detecção e maturação de café.	F1-score de 82%.
(ORTENZI et al., 2021)	Visão computacional e classificador KNN baseado em RGB.	Maturação de olivas.	Acurácia de 60%.
(KHEIRALIPOUR; NADIMI; PALIWAL, 2022)	Visão computacional, extrator de características e LDA, QDA e ANN para classificação.	Maturação de pistachos.	Taxa de acerto de classificação 93,7% 97,5% e 100%.
(BAZAME et al., 2022)	YOLOv4, YOLOv4-tiny, YOLOv3 e YOLOv3-tiny.	Detecção e maturação de café em ramos das plantas.	mAP de 81% a 77%.
(CHEN et al., 2022a)	Faster R-CNN, RetinaNet, SSD, YOLOv7 e Citrus-YOLOv7.	Detecção de citrus pomares.	mAP de 82,93% a 97,29%.
(YUAN, 2023)	YOLOv4 e YOLOv7.	Classificação de botão de flor de maçã.	mAP de 0,407 a 0,799.
(LAI et al., 2023)	YOLOv4-tiny, YOLOv5s, YOLOv7 e YOLOv7 modificado.	Detecção e maturação de abacaxi.	Precisão média de 84,6% a 97,5%.
(MACEACHERN et al., 2023)	YOLOv3, YOLOv3-SPP, YOLOv3-tiny, YOLOv4, YOLOv4-small e YOLOv4-tiny.	Detecção e maturação de mirtilo.	F1-score de 0,66 a 0,79.

Fonte: Do autor (2023).

### 3. MATERIAL E MÉTODOS

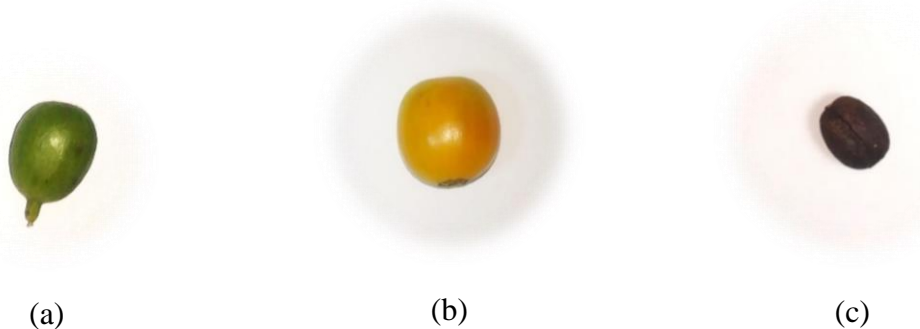
As informações encontradas na revisão bibliográfica serviram de base para a realização desse estudo. Assim, foi desenvolvido um dispositivo para coletar imagens dos frutos de café durante o processo de colheita mecanizada e, posteriormente, classificá-los de acordo com o grau de maturação utilizando algoritmos de visão computacional. A seguir estão descritos a área de estudo e os equipamento utilizados para coleta de imagens, o algoritmo proposto de visão computacional e, também, o modelo da rede YOLO utilizada para classificação dos frutos, a forma de validação dos resultados do algoritmo, as métricas utilizadas para a avaliação de desempenho do algoritmo e da rede YOLO e, por fim, o hardware e bibliotecas utilizadas.

#### 3.1. Caracterização da área de estudo e máquina colhedora utilizada

As imagens utilizadas neste estudo foram obtidas no período de 19 a 25 de julho de 2022 na Fazenda Cafua localizada no município de Ijaci na região Sul do estado de Minas Gerais. As áreas de estudo são cultivadas com café arábica (*Coffea arabica* L.) da cultivar Bourbon Amarelo. Uma característica dessa cultivar são os frutos da cor amarela quando estão maduros. A máquina colhedora Case, modelo Coffee Express 200 foi utilizada na colheita dos frutos.

As cores externas dos frutos de café nos estágios não maduro, maduro, e demasiado maduro eram predominantemente próximas das cores verde, amarelo e marrom, respectivamente. Esses três estádios de maturação são comumente utilizados para classificação de frutos ((BAZAME et al., 2021; KHOJASTEHNANZHAND; MOHAMMADI; MINAEI, 2019). A Figura 8 apresenta as três classes de frutos: fruto não maduro (verde), fruto maduro (amarelo) e fruto demasiado maduro (marrom).

**Figura 8** – Imagens de frutos de café representantes de cada uma das classes utilizadas nesse estudo. (a) fruto não maduro da cor verde, (b) fruto maduro da cor amarelo e (c) fruto demasiado maduro da cor marrom.



Fonte: Do autor (2023).


### 3.2. Dispositivo para aquisição de imagens

Para obter as imagens de frutos de café, foi desenvolvido um dispositivo para capturar imagens dos frutos de café durante o processo de colheita. O dispositivo foi desenvolvido considerando as condições de trabalho da colhedora. Este sistema foi composto por:

- (i) Suporte para acoplamento na máquina colhedora;
- (ii) Suporte de acoplamento antivibração para a câmera;
- (iii) Câmera de vídeo GoPro Hero 7 a uma distância de 32 cm da esteira. As imagens foram obtidas de vídeos em definição full HD (1920x1080), 120 fps, 720P, ISO 3200 e 1/960 de tempo de abertura do obturador;
- (iv) Sistema de iluminação por LED com 4 lâmpadas de 3,5 W;
- (v) Cortinas de borracha.

O dispositivo foi projetado para minimizar os efeitos da variação de iluminação natural nas imagens coletadas. Para isso, possui sistema de iluminação por led com luz cor branca fosco e cortinas de borracha que minimizam a entrada de luz solar no ambiente de coleta dos vídeos, sem interferir no fluxo contínuo de frutos colhidos transportados pela esteira. A câmera é acoplada em um suporte unido ao dispositivo que possui 4 borrachas de amortecimento de cabeça dupla para reduzir o efeito de vibração da máquina colhedora durante a coleta de imagens. A Figura 9 apresenta o dispositivo desenvolvido para realizar este estudo.

**Figura 9** – Dispositivo para captura de imagens dos frutos de café colhidos.



Fonte: Do autor (2023).

O dispositivo foi desenvolvido para ser acoplado na colhedora, posicionado sobre a esteira transversal e entre os transportadores verticais. A esteira transversal conduz os frutos colhidos para o tanque graneleiro ou para a bica de descarga, dependendo das necessidades do processo de colheita. Assim, as imagens coletadas correspondem aos frutos derriçados de um dos lados das plantas de café. E, posteriormente, na próxima passada da colhedora são coletadas as imagens dos frutos que correspondem ao outro lado das plantas de café da linha de plantio adjacente. Sendo que a colhedora realiza a passada de ida em uma linha de plantio de café e passada de volta na linha de plantio adjacente. Na Figura 10 é apresentado o dispositivo acoplado na colhedora.

**Figura 10** – Dispositivo acoplado na máquina colhedora de café para coleta de imagens. (a) Imagem lateral do dispositivo acoplado na máquina colhedora sobre a esteira transversal de transporte dos frutos colhidos. (b) Vista traseira da máquina colhedora de café com o dispositivo acoplado, localizado na parte superior da máquina e sobre a esteira transversal.



(a)



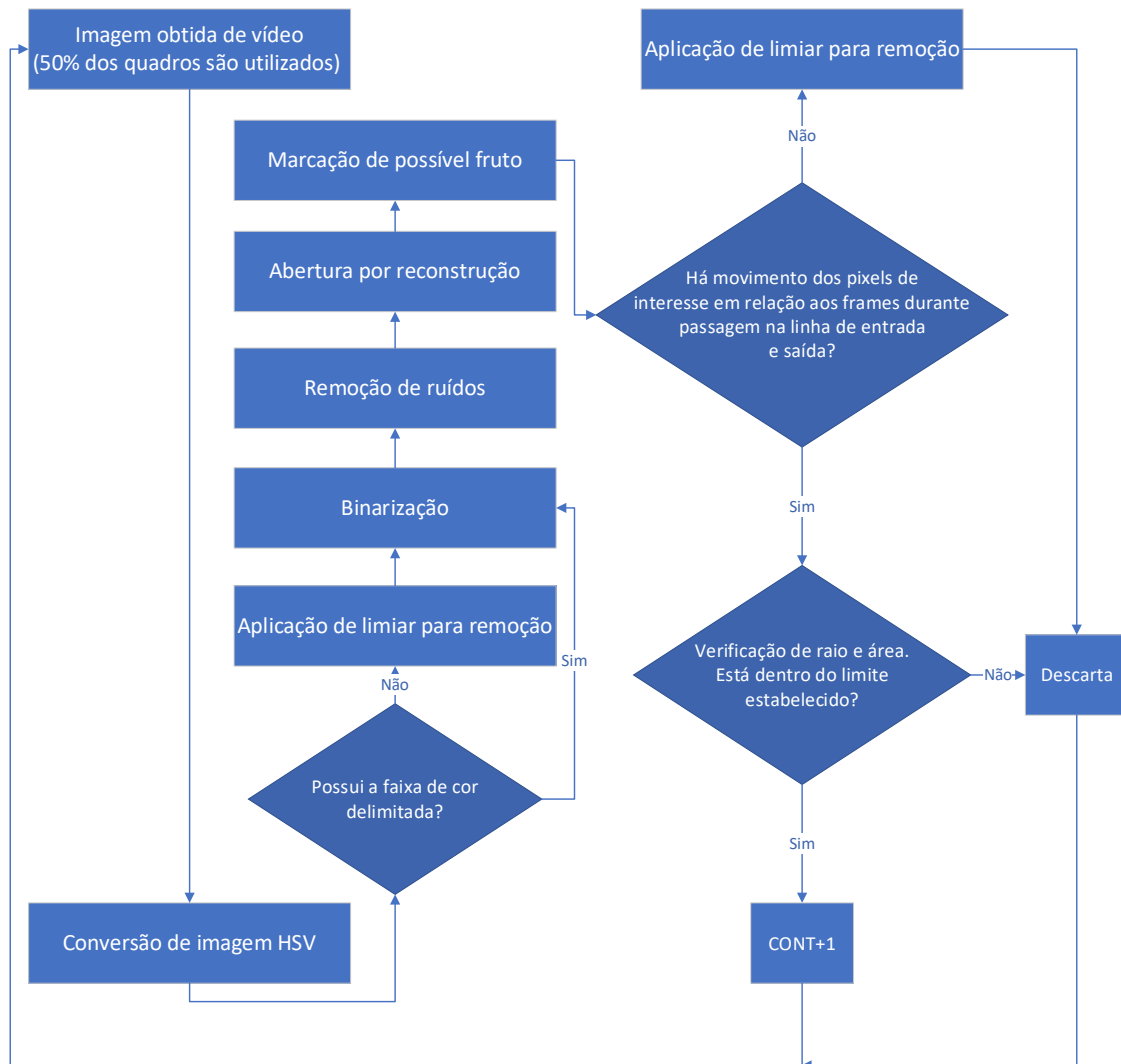
(b)

Fonte: Do autor (2023).

### 3.3. Processamento digital de imagens para classificação de frutos de café

A Figura 11 representa o fluxograma das várias etapas do algoritmo proposto para identificar o grau de maturação dos frutos de café, as etapas serão discutidas em detalhes a seguir.

**Figura 11** – As etapas da operação de classificação da maturação dos frutos de café colhidos.



Fonte: Do autor (2023).

Trabalhos anteriores demonstraram o uso de vários espaços de cores para avaliação dos níveis de amadurecimento de frutas (KHEIRALIPOUR; NADIMI; PALIWAL, 2022; KHOJASTEHNASHAND; MOHAMMADI; MINAEI, 2019). O modelo de cores HSV é facilmente interpretável por humanos, como matiz (H), saturação ou pureza de cor (S) e brilho (V). Neste trabalho, as imagens foram transformadas para o espaço HSV e obtidos os intervalos de valores que representam as faixas de cor de frutos de café para cada grau de maturação. As cores predominantes para cada grau de maturação não maduro, maduro e demasiado maduro são: verde, amarelo e marrom, respectivamente. Foi aplicado limiar para remoção das cores que não são de interesse.

Com as cores de interesse, foi realizado o processamento de imagens binárias que visou detectar grupos de pixels conectados e obter as informações das propriedades de interesse como forma, tamanho e localização. Após a remoção de ruídos com aplicação de filtro, foi realizada

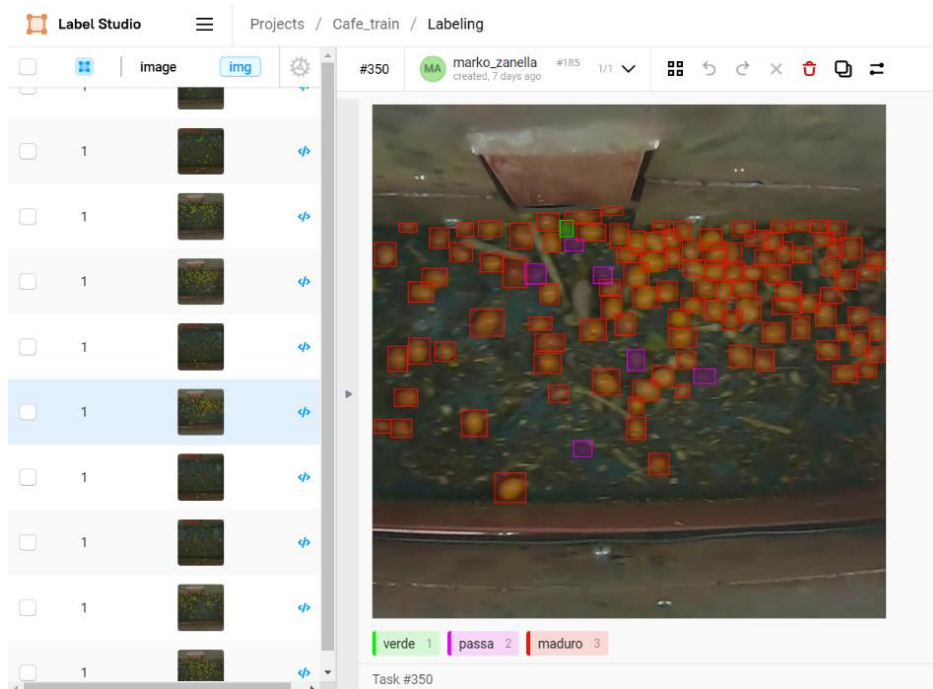
a remoção de pequenos objetos não desejáveis. A abertura por reconstrução que é o efeito da abertura morfológica (erosão seguida por dilatação) permite que os objetos que restaram após a erosão sejam restaurados à forma original (SOLOMON; BREACKON, 2013). Este processo facilita a realização da próxima etapa uma vez que os frutos apresentam o formato circular. Foram delimitados os valores de pixels das bordas, raio e área para os limites de interesse (tamanho dos frutos). Então o algoritmo verifica se há movimento dos pixels de interesse, para isso foi utilizado duas linhas para fazer o acompanhamento dos pixels delimitados. A etapa que antecede a contagem é a verificação se os pixels em movimento, possuem cor, tamanho e forma conforme as delimitadas para os frutos de café.

### **3.4. Pré-processamento e anotação de imagens para a rede YOLOv7**

As imagens utilizadas para o treinamento e teste da rede foram padronizadas no tamanho de 720 por 720 pixels. Foram extraídas uma imagem a cada 60 quadros de 4 vídeos com duração de 6 a 9 minutos coletados durante a colheita de café. Desses foram selecionados aleatoriamente 265 quadros para compor o banco de imagens. As imagens foram anotadas conforme a classificação dos frutos presentes de acordo com o grau de maturação das 3 classes: não maduro, maduro e demasiado maduro. Para fazer as anotações nas imagens foi utilizado a ferramenta Label-Studio (TKACHENKO et al., 2022) e caixas delimitadoras (do inglês *bounding box*) para delimitar a localização dos frutos na imagem. A Figura 12 representa a interface da ferramenta de anotação e um exemplo de imagem anotada.



**Figura 12** – Interface da ferramenta de anotação para dados de entrada na rede YOLO e exemplo de imagem anotada.



Fonte: Do autor (2023).


Os arquivos exportados da ferramenta de anotação e utilizados para o treinamento da rede são imagens e um arquivo de texto associado a cada imagem. Esse arquivo de texto possui a identificação de cada classe anotada existente na imagem e as coordenadas de localização do centro da caixa delimitadora seguido das dimensões altura e comprimento. As anotações são normalizadas para que os valores presentes no arquivo de texto estejam no intervalo de 0 a 1.

### 3.5. YOLOv7 e configurações adotadas

O algoritmo para detecção de objetos YOLO (REDMON et al., 2016) vem sendo aprimorado nos últimos anos. Nesse estudo foi utilizado sua última versão, o modelo YOLOv7, que superou seus antecessores em velocidade de processamento e acurácia (WANG; BOCHKOVSKIY; LIAO, 2022). Apesar de algumas mudanças em relação as versões anteriores, a estrutura básica do YOLOv7 continua sendo composta de três partes principais: coluna vertebral, pescoço e cabeça (do inglês *backbone*, *neck* e *head*). Antes de passar por cada uma destas etapas, primeiramente a rede Yolov7 pré-processa e redimensiona a imagem de entrada em 640 x 640 x 3 para ter um tamanho de pixel uniforme que atende os requisitos de processamento, então insere a imagem na rede na parte *backbone*.

Toda a estrutura da rede é constituída de vários módulos. A parte conhecida como *backbone* é onde as características das imagens são extraídas, sendo composta de camadas de convolução Bconv, MPCConv e E-ELAN. Um conjunto de módulos CBS compõem o Bconv. CBS são os módulos mais básicos da rede e integram outros módulos, são compostos de convolução, normalização de conjunto e funções de ativação SiLU (do inglês *Sigmoid-weighted linear units*). MPCConv é composto por CBS e MaxPool. CBS extrai todos os valores de pequenas áreas e MaxPool extrai apenas os valores máximos dessas áreas, melhorando a capacidade de extração de características da rede (LIU et al., 2023). Os módulos EELAN (do inglês *Extended Efficient Layer Aggregation Network*) são os principais da rede YOLOv7. De acordo com os autores da rede YOLOv7 Wang, Bochkovskiy e Liao (2022), esses módulos permitem aprimorar continuamente o aprendizado da rede ao expandir, embaralhar e mesclar a cardinalidade sem destruir o caminho original do gradiente. Os módulos EELAN que estão presentes na parte *backbone* vão concluir a tarefa de extração das principais características em seguida as enviando para a parte *neck*. Por fim, as características extraídas se fundem com uma operação de concatenação (Cat). A Figura 13 apresenta os módulos ELAN utilizados nas partes *backbone* e *neck* da rede YOLOv7.

**Figura 13** – Imagem dos módulos EELAN em que os módulos ELAN-1 estão presentes na parte *backbone* e os módulos ELAN-2 estão presentes na parte *neck* da rede.



Fonte: Imagem reproduzida de Chein et al. (2023).

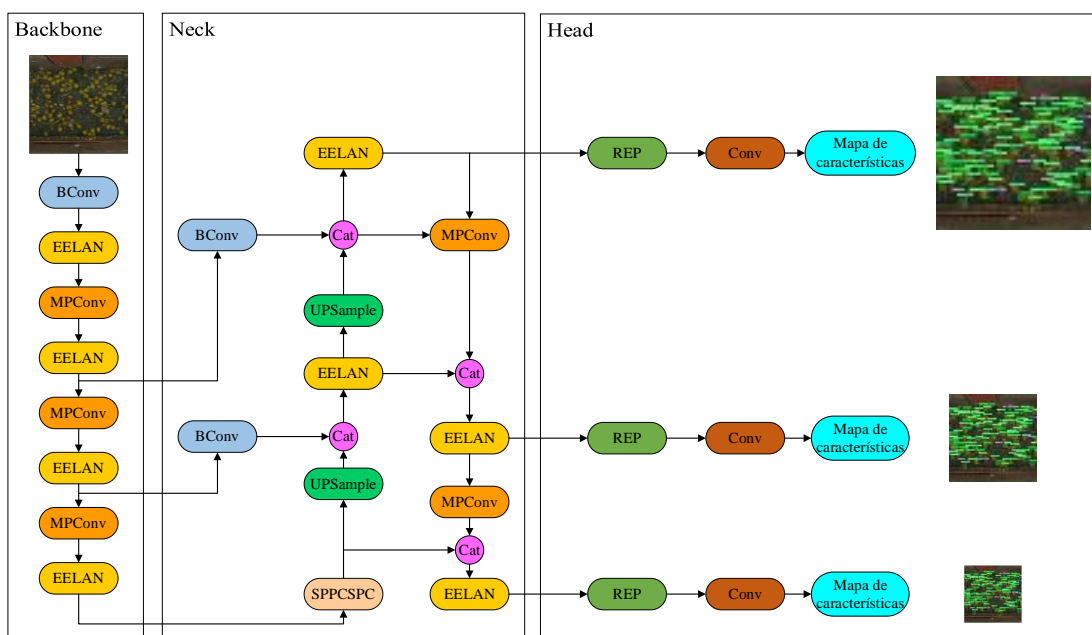
As características extraídas das imagens de entrada na parte *backbone* são integradas e misturadas na parte seguinte conhecida como *neck*. Uma estrutura de pirâmide de característica é usada com a estrutura SPPCSPC e módulos EELAN. O módulo SPPCSPC é formado por uma estrutura CSPNet com bloco de SPP. CSPNet (do inglês *Cross Stage Partial Network*) foi desenvolvido para reduzir as informações de gradiente redundantes, e consequentemente, o uso de memória da rede, otimizando a velocidade e precisão (WANG et al., 2019). O SPP (do inglês *Spatial Pyramid Pooling Layer*) é utilizado para auxiliar na manipulação de diferentes escalas e tamanhos de imagens (HE et al., 2014). Os módulos EELAN nesta parte da rede tem uma

composição diferente daqueles na parte *backbone* (Figura 14). Por fim, as características são repassadas para a parte chamada de *head*.

Na parte da estrutura do YOLO conhecida como *head* é onde ocorre as predições. A rede realiza as predições de saída por três mapas de características. REP utiliza uma técnica de reparametrização estrutural (DING et al., 2021). Essa estrutura combina convolução  $3 \times 3$ , convolução  $1 \times 1$  e conexão de identidade em uma camada convolucional, proporcionando maior diversidade de gradientes para os mapas de características (WANG; BOCHKOVSKIY; LIAO, 2022). Os três mapas apresentam as seguintes escalas: 20x20, 40x40 e 80x80. Essas escalas correspondem ao tamanho do alvo respectivamente, pequeno, médio e grande (ZHANG et al., 2023). Os mapas de características de saída formam um vetor unidimensional chamado de camada totalmente conectada (CHEN et al., 2023). Posteriormente, gerando probabilidade de categoria prevista, confiança e coordenadas da caixa em que o alvo está inserido.

A função de perda utilizada na rede YOLOv7 é semelhante ao utilizado na rede YOLOv5, em que esta é dividida em perda de confiança do objeto, perda de classificação e perda de coordenadas. A perda de confiança do objeto e a perda de classificação utilizam a perda de entropia cruzada BCE. E a perda de coordenadas utiliza a equação de perda CloU (LIU; ANGUELOV, 2016). Essa função melhora a precisão de detecção em relação ao problema de caixas de detecção não sobrepostas (CHEN et al., 2022a). A Figura 14 apresenta a estrutura do modelo YOLOv7.

**Figura 14** – Figura representando os módulos que compõe a estrutura original da rede YOLOv7.



Fonte: Imagem adaptada de Lai et al. (2023).


A técnica de aprendizado por transferência (do inglês *transfer learning*) foi utilizada. Essa técnica permite ajustar um modelo pré-treinado em um conjunto de dados mais abrangente e com maior número de imagens, para detecção de um objeto escolhido em que neste estudo foram os frutos de café. O processo de pré-treinamento foi realizado sobre o conjunto de dados MS COCO (LIN et al., 2014) que possui 330 mil imagens e 80 categorias de objetos. Essa estratégia permite obter melhores resultados sem a necessidade de produzir um número enorme de imagens anotadas para realizar o treinamento da rede para detecção de um objeto específico. Uma vez que os pesos do modelo pré-treinado são transferidos e se pode completar o treinamento com as características extraídas do objeto posterior.

Os principais hiperparâmetros da rede YOLOv7 foram definidos de acordo com os valores recomendados na bibliografia. Assim, o valor utilizado para a taxa de aprendizado foi de 0,01. Esse é um dos parâmetros mais importantes e interfere nos resultados de tempo do processo de treinamento, que pode ser muito elevado para uma taxa muito baixa, e no efeito de treinamento, que pode resultar abaixo do ideal. Outros parâmetros importantes são o coeficiente de atenuação do peso que foi definido como 0,0005, o otimizador selecionado foi SGD (do inglês *Stochastic Gradient Descent*), o lote de treinamento foi definido em 16 e o ciclo de iteração foi definido em 100 épocas. Após o treinamento, o arquivo de peso foi salvo e usado no teste da rede YOLOv7.

### **3.6. Metodologia e parâmetros para avaliação da classificação**

Para validar os resultados com parâmetros estabelecidos, foi utilizada a validação cruzada em 10 seguimentos de vídeos de 5 segundos que se sobrepõem em 2 segundos. Foram utilizados 2 vídeos, chamados no estudo de Teste 01 e Teste 02, para obter 10 seguimentos de cada. A Figura 15 ilustra a obtenção dos vídeos para a validação. Os vídeos utilizados para a obtenção dos parâmetros foram diferentes dos vídeos utilizados para a validação. A contagem visual foi realizada em imagens (quadros dos vídeos) para estabelecer a quantidade total dos frutos de cada grau de maturação em cada segmento de vídeo. A contagem visual foi considerada o valor padrão. Posteriormente foi realizada a relação entre os totais resultantes da contagem visual e os totais resultantes da classificação com o algoritmo, para obter a porcentagem de acerto.

**Figura 15** - Imagem representativa da obtenção dos vídeos para a validação cruzada.



Fonte: Do autor (2023).

O desempenho do processamento proposto também foi avaliado comparando amostras de frutos de café classificados pelo algoritmo em um único frame do vídeo com a classificação visual desses frutos (padrão). Nesse caso, foi possível quantificar os frutos de cada grau de maturação que foram classificados erroneamente pelo algoritmo. Para esta avaliação foram selecionados aleatoriamente 50 imagens dos 20 vídeos utilizados na validação cruzada.

Os critérios usados para avaliar o desempenho foram Precisão, *Recall* e *F1-Score* sendo calculados conforme as Equações (2), (3) e 4). Para avaliar o modelo YOLO, além das métricas mencionadas, foi calculada a mAP (do inglês *mean Average Precision* - mAP) descrita na Equação (6) utilizando AP que é descrita na Equação (5).

$$\text{Precisão} = \frac{VP}{(VP + FP)} \quad (2)$$

$$\text{Recall} = \frac{VP}{(VP + FN)} \quad (3)$$

$$\text{F1 - Score} = \frac{2 \times \text{Precisão} \times \text{Recall}}{(\text{Precisão} + \text{Recall})} \quad (4)$$

$$AP = \int_0^1 P(R) dR \quad (5)$$

$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n AP_i \quad (6)$$

A precisão indica a porcentagem de detecção correta, sendo a confiabilidade do modelo na classificação de amostras como positivas. *Recall* indica a porcentagem de frutos de café que foram detectados com sucesso. O *F1-Score* é a média ponderada entre as taxas de precisão e *recall*. E mAP é o valor médio de AP e reflete a acurácia do modelo. Precisão, *Recall* e *F1-Score* foram calculados dos valores de VP, FP e FN em que: Verdadeiro Positivo – VP: Indica o número de frutos detectados adequadamente. Falso Positivo – FP: O número de frutos que foi classificado como fundo da esteira ou mal classificados. Falso Negativo – FN: O número de frutos que não foram classificados.

### **3.7. Descrição dos equipamentos e ferramentas utilizadas**

O processamento foi realizado utilizando a ferramenta Google Colaboratory. O equipamento disponível nessa ferramenta foi uma estação de trabalho com CPU Intel(R) Xeon(R) de 2,00 GHz e uma placa gráfica NVIDIA Tesla T4 com 16 GB de memória. Todos os softwares envolvidos no processamento foram programados em Python, linguagem versão 3. Para a programação de todos os softwares relacionados ao processamento de imagem e ao modelo YOLOv7 (<https://github.com/WongKinYiu/yolov7.git>) foram utilizadas as bibliotecas OpenCV e PyTorch.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. Avaliação do dispositivo para coleta de imagens

O dispositivo fabricado foi acoplado sobre a esteira transversal de transporte dos frutos colhidos da colhedora de café. Em um estudo similar para classificação da maturação dos frutos de café, Bazame et al. (2021) adaptaram uma câmera na bica de saída da colhedora, tendo o objetivo de obter imagens de todos os frutos colhidos para gerar mapas de maturação. Entretanto, muitos modelos de colhedoras de café possuem um tanque graneleiro que possibilita autonomia de armazenamento de frutos colhidos para a máquina. Assim, se pode realizar a colheita sem descarregar simultaneamente. A coleta pode ser realizada durante a colheita mesmo quando a máquina está colhendo e armazenado em seu tanque graneleiro ou, quando está colhendo e descarregando em uma carreta tracionada por um trator que se move ao lado da colhedora. Além disso, o dispositivo desenvolvido pode ser adaptado em diferentes modelos de máquinas colhedoras.

As imagens obtidas utilizando o dispositivo apresentaram um bom nível de padronização, mesmo com a variação da incidência de luz solar sobre o dispositivo. Apesar do controle de iluminação, com o processamento das imagens, foi observado que o sistema de iluminação utilizado pode ser melhorado, sendo necessário aumentar a intensidade luminosa. Neste trabalho, as paredes do dispositivo refletiam a luz proveniente do sistema de iluminação por led. Um melhor resultado pode ser obtido com paredes da cor branca para ter melhor difusão da iluminação. A iluminação pode ser um problema para realizar o processamento das imagens e diminuir a acurácia de algoritmos de detecção de objetos. Em estudo de Bazame et al. (2021) a variação da iluminação ocasionada pela entrada de luz solar durante a colheita foi apontada como fator que interferiu negativamente nos resultados da classificação dos frutos.

As configurações da câmera utilizadas possibilitaram a obtenção dos vídeos para o processamento. Nesse estudo, durante o processamento, foram realizadas avaliações os vídeos obtidos e constatado que é possível reduzir a taxa de quadros por segundo (do inglês *frames per second* - fps) para 60 sem prejudicar os resultados do processo de classificação dos frutos. Além disso, com maior intensidade luminosa se pode ajustar velocidade e a abertura do obturador da câmera, reduzindo a abertura e aumentando a velocidade do obturador para obter imagens com melhor definição dos frutos em movimento. O valor de ISO da câmera, que é o ajuste de sensibilidade a luz, também pode ser reduzido para evitar visibilidade de ruídos.

A Figura 16 mostra uma imagem dos frutos de café na esteira de transporte utilizada neste estudo. Na imagem é possível observar aglomeração e sobreposição de frutos, e a esteira

com acúmulo de impurezas. Essas condições mais difíceis para a realização do presente estudo, mas são condições inerentes ao processo de colheita. Em uma colhedora realizando o processo de colheita não é possível modificar a cor da esteira onde os frutos são transportados, pois rapidamente estaria impregnada com impurezas resultantes do processo de colheita. No entanto, o acúmulo de impurezas impregnadas na esteira dificultou a classificação da classe demasiado maduros, para as outras classes esse problema não atrapalhou a classificação. No entanto, a presença de impurezas maiores pode encobrir os frutos e impossibilitar sua identificação. A aglomeração dos frutos depende da produtividade das plantas e dinâmica de colheita. No estudo de Bazame et al. (2021), as imagens utilizadas para a classificação apresentam frutos mais espalhados e em um fundo branco, sendo condições não convencionais ao processo de colheita.

**Figura 16** – Imagem dos frutos de café na esteira transportadora.



Fonte: Do autor (2023).

#### **4.2. Avaliação do algoritmo de processamento digital proposto**


Os resultados do processamento realizado no conjunto de dados de imagens de frutos de café colhidos são apresentados a seguir. A classificação do grau de maturação dos frutos de café foi realizada conforme o fluxograma do algoritmo proposto neste estudo e apresentado na Figura 11.

Os parâmetros para o processamento dos vídeos foram obtidos em vídeos distintos daqueles utilizados na validação. Os parâmetros ajustados são borda, raio, área e cor. Os intervalos de valores para os parâmetros são contabilizados em pixels. Para o parâmetro cor os intervalos são estabelecidos de acordo com o espaço de cor HSV e variam de acordo com a cor predominante em cada grau de maturação dos frutos. Os valores do matiz (H) variam de 0 a 180, saturação (S) e brilho (V) variam de 0 a 255. Os intervalos de valores de borda, raio e área são: 1-5, 1-5 e 1-15, respectivamente. Os frutos não maduros são predominantemente da cor



verde, os valores dos intervalos de matiz, saturação e brilho são: 43-62, 100-220, 50-255, respectivamente. Os frutos maduros são predominantemente da cor amarela, os valores dos intervalos de matiz, saturação e brilho são: 20-40, 145-255, 15-110, respectivamente. Os frutos demasiados maduros são predominantemente da cor marrom, os valores dos intervalos de matiz, saturação e brilho são: 0-15, 130-255, 100-160, respectivamente. No entanto, os resultados da identificação e classificação dos frutos da classe demasiado maduro não foram satisfatórios devido a semelhança desses frutos com as impurezas presentes na esteira de transporte. A Figura 17 representa o resultado de cada etapa do processamento das imagens proposto no fluxograma da Figura 11.

**Figura 17** – O resultado de diferentes etapas do processamento, (a) imagem original, (b) imagem em escala de cores HSV, (c) máscara, (d) binarização, (e) remoção de ruídos, (f) abertura por reconstrução, (g) identificação do fruto, e (h) acompanhamento de movimento.



Fonte: Do autor (2023).

Neste estudo a utilização do espaço HSV foi eficiente para separar as classes de maturação não maduro e maduro. Lopez, Cobos e Aguilera (2011) utilizaram os espaços RGB e HSV para testar o sistema de classificação de falhas em citrus, e observaram que os resultados com o espaço HSV foram melhores. Na Tabela 2 são apresentadas as quantidades de frutos em cada conjunto de vídeos utilizada para a validação cruzada, onde a contabilização dos frutos foi realizada visualmente (padrão) e, posteriormente, com a implementação do algoritmo. O Teste 01 apresentou uma quantidade menor de frutos quando comparado com o Teste 02. Total de 7579 frutos no Teste 01 e total de 19655 frutos no Teste 02, embora exista variação na quantidade de frutos entre os vídeos do mesmo conjunto. A quantidade de frutos não maduros não apresentou grande variação em cada conjunto de vídeos, variando de 8 até 21 frutos como pode ser observado na Tabela 2.

**Tabela 2** – Resultados da quantificação dos frutos nos graus de maturação não maduros e maduros realizada por contagem visual (padrão) e com a utilização do algoritmo proposto para cada seguimento de vídeo utilizado na validação.

Id.	Teste 01				Teste 02			
	Padrão		Algoritmo		Padrão		Algoritmo	
	Não maduro	Maduro	Não maduro	Maduro	Não maduro	Maduro	Não maduro	Maduro
K1	17	354	14	245	15	1954	9	1491
K2	13	454	8	363	13	2175	12	1394
K3	11	459	8	338	15	1965	12	1458
K4	15	666	13	487	21	1899	12	1276
K5	19	842	16	496	23	1826	17	1201
K6	7	831	20	531	3	1783	19	1281
K7	22	1565	21	953	16	1789	20	1218
K8	15	1375	6	882	15	1779	13	1267
K9	10	568	17	397	18	2196	13	1413
K10	7	329	13	245	13	2137	9	1401

Fonte: Do autor (2023).

Na Tabela 3 são apresentados os percentuais de acerto do algoritmo para a classificação dos frutos não maduros e maduros para cada um dos testes. Os valores percentuais foram obtidos dividindo a quantidade de frutos contabilizado com o algoritmo proposto pelo total de frutos que foi contabilizado manualmente.

**Tabela 3** – Resultado da porcentagem de acerto da quantificação realizada com o algoritmo em relação a quantificação visual (padrão).

Identificação	Teste 01		Teste 02	
	Não maduro	Maduro	Não maduro	Maduro
K1	0,82	0,69	0,60	0,76
K2	0,62	0,80	0,92	0,64
K3	0,73	0,74	0,80	0,74
K4	0,87	0,73	0,57	0,67
K5	0,84	0,59	0,74	0,66
K6	0,55	0,64	0,41	0,72
K7	0,95	0,61	0,55	0,68
K8	0,40	0,64	0,87	0,71
K9	0,77	0,70	0,72	0,64
K10	0,93	0,74	0,69	0,66

Fonte: Do autor (2023).

Os vídeos com maior quantidade de frutos foram aqueles com menor valor de acerto na classificação realizada com o algoritmo como observado na Tabela 3. Uma quantidade muito grande de frutos pode ocasionar a sobreposição parcial de frutos dificultando a identificação de cada fruto. A distribuição de frutos ao longo da esteira pode variar de acordo com o movimento

da colhedora e a quantidade de frutos colhidos. Na Tabela 4 são apresentados os valores médios de acerto de cada teste da classificação apresentada na Tabela 3.

**Tabela 4** – Porcentagem média de acerto resultante da classificação dos frutos de café de acordo com o grau de maturação utilizando o algoritmo proposto.

Avaliação	Não maduro		Maduro	
	Média	Desvio padrão	Média	Desvio padrão
Teste 01	0,75	0,1764	0,7	0,0668
Teste 02	0,7	0,1568	0,7	0,0421

Fonte: Do autor (2023).


Em comparação entre as duas classes de maturação, o nível de acerto dos frutos não maduros e maduros praticamente não diferenciou. Essa similaridade de valores entre as classes também foi observada em estudo de Bazame et al. (2021), em que os autores obtiveram valores de precisão próximos para a classificação dos frutos de café não maduros e maduros, com valores de precisão média de 86,0% e 85,0%

Na Figura 18 são apresentadas imagens obtidas do resultado da classificação realizado com o algoritmo proposto em imagens. As Figuras 18a e 18b são imagens originais e as Figuras 18c e 18d são os resultados da classificação para os graus de maturação maduros e não maduros, respectivamente. Essa classificação foi realizada em imagens obtidas dos vídeos. A obtenção dessas imagens foi sem a etapa de contagem do algoritmo proposto, as imagens demonstram a capacidade do algoritmo em identificar cada classe de maturação dos frutos.


**Figura 18** – Imagem dos frutos na esteira transportadora. (a) e (b) são imagens originais, (c) e (d) são os resultados da classificação para os frutos em grau de maturação maduros e não maduros, respectivamente.



(a)



(c)

**Figura 19** – Continuação.

Fonte: Do autor (2023).

A avaliação do algoritmo também foi realizada em 50 imagens obtidos aleatoriamente para obter os valores de precisão, recall e F1-score. Para a avaliação da classificação de frutos maduros foram obtidos valores de 72%, 75% e 74% de precisão, recall e F1-score, respectivamente. Para a avaliação da classificação de frutos não maduros foram obtidos valores de 77%, 71% e 74% de precisão, recall e F1-score, respectivamente.

Os resultados de precisão, recall e F1-score para as imagens foram acima dos valores obtidos na validação cruzada utilizando os segmentos de vídeos. Isso pode ser explicado por uma possível baixa intensidade da iluminação. Além disso, a dinâmica de colheita e variações na declividade do terreno também podem interferir na quantidade e na distribuição dos frutos que passam na esteira transversal. Essa possível variação de precisão na classificação dos frutos também foi relatada por Bazame et al. (2021).

Outros estudos aplicaram técnicas de visão computacional para classificação de maturação dos frutos. Ortenzi et al. (2021) classificaram a maturação de lotes de azeitonas também utilizando o espaço HSV para extrair características dos frutos e, posteriormente, utilizaram o algoritmo KNN para fazer a classificação, obtendo resultado de 60% na validação. Os autores sugeriram melhorias como suporte para a câmera e limpeza dos lotes de azeitonas. Kheiralipour, Nadimi e Paliwal (2022) desenvolveram um sistema para classificação da maturação de pistachos baseado em visão computacional. Os autores obtiveram acurácia acima de 93% na classificação. No entanto as imagens foram obtidas em laboratório e com fundo branco, facilitando o processamento e possibilitando melhores resultados. Esses estudos demonstram que técnicas de visão computacional necessitam de alta padronização de imagens para obter melhores resultados de classificação. Embora a coleta de imagens possa ser


melhorada, outros fatores como presença de impurezas e aglomeração de frutos são inerentes ao processo de colheita.

Algoritmos de visão computacional podem ser implementados em máquinas colhedoras para melhorar o processo de colheita. Zhao et al. (2022) desenvolveram um sistema para coletar e processar imagens para detecção de entupimento de peneira em colhedoras de milho. O sistema tem o potencial de ser implementado em uma colhedora através da integração de um sistema de hardware embarcado. De mesma forma, algoritmo proposto foi capaz de realizar a classificação dos frutos de café com precisão média de 70% para os frutos maduros e 72% para os frutos não maduros. O algoritmo proposto utiliza apenas características de cor e forma para realizar a classificação dos frutos. E pode ser ajustado para diferentes condições sem necessidade de um extenso conjunto de dados. Sendo a iluminação um dos principais fatores que interfere negativamente nos resultados.

### 4.3. Avaliação de desempenho da rede YOLO v7

O conjunto de dados foi dividido em duas partes selecionando imagens aleatoriamente: oitenta por cento (212 imagens) foi usado para treinamento e vinte por cento (53 imagens) foi usado para teste. Os resultados desse procedimento são detalhados a seguir. Na Figura 19 é apresentado a variação da precisão da rede YOLOv7.


**Figura 20** – Curvas de precisão do modelo de detecção YOLOv7 para as três classes e para todas juntas.



Fonte: Do autor (2023).

A Precisão demonstra a qualidade do modelo em prever cada uma das classes. É observado na Figura 19 que o melhor desempenho da rede foi para a classe de frutos maduros e o pior desempenho para a classe não maduros. Esse pior desempenho apresentado para a classe de frutos não maduros pode estar relacionado ao menor número de frutos não maduros presentes no banco de dados. Com menor amostra de frutos dessa classe a rede tem mais dificuldade para identificar e classificar esse tipo de frutos. Na Figura 20 é apresentado a variação da recall da rede YOLOv7.

**Figura 21** – Curvas de recall do modelo de detecção YOLOv7 para as três classes e para todas juntas.




Fonte: Do autor (2023).

O Recall é uma métrica que indica a capacidade do modelo em detectar corretamente uma determinada categoria. Na figura 20, é possível observar as curvas de Recall para cada classe de fruto de café. É importante notar que a curva correspondente à classe "demasiado maduro" apresenta um desempenho inferior às outras classes. Esse resultado pode estar relacionado à dificuldade da rede em detectar e classificar frutos dessa classe, uma vez que eles podem ser confundidos com o fundo da imagem, que é a esteira de transporte de frutos. Vale destacar que essa dificuldade pode ser ainda maior quando há variações na iluminação e na posição dos frutos. O estudo de (BAZAME et al., 2021) também relatou menor precisão na classificação dessa classe de frutos. Os autores indicaram que possível motivo para o pior

desempenho foi devido a semelhança com os frutos maduros que eram da cor vermelho escuro. A curva PR (Precisão-Recall) é representada na Figura 21.


**Figura 22** – Curvas de precisão-recall do modelo de detecção YOLOv7 para as três classes e para todas juntas.



Fonte: Do autor (2023).

A curva precisão-recall representa a relação entre os índices de precisão e recall, indicando a capacidade do modelo em detectar e classificar corretamente as amostras. Quanto maior a precisão e recall, melhor o desempenho do modelo. A elevada área sob a curva representa alta recall e alta precisão, em que a precisão elevada está relacionada a uma baixa taxa de falsos positivos e elevada recall está relacionada a uma baixa taxa de falsos negativos. A classificação das classes maduro e não maduro resultou os valores de 0,975 e 0,893, respectivamente. No entanto, a classe demasiado maduro apresentou o valor de 0,679 que é muito abaixo quando comparado com as outras classes. Na Figura 22 está representado a variação dos valores de F1-score para cada classe de maturação e para todas juntas.

**Figura 23** – Curvas de F1-score do modelo de detecção YOLOv7 para as três classes e para todas juntas.



Fonte: Do autor (2023).

O parâmetro F1 é uma média harmônica de Precisão e Recall, sendo este parâmetro mais sensível aos valores das métricas utilizadas para o cálculo, em caso a uma das duas variáveis de entrada apresentar um valor baixo. A classe demasiado maduro apresentou um desempenho pior devido aos baixos valores de recall que está relacionado aos falsos negativos na classificação, ou seja, reflete a dificuldade em reconhecer os frutos dessa classe.

No teste, a rede foi avaliada em 53 imagens que representam 20% do conjunto de dados e não fizeram parte do treinamento da rede. O teste foi avaliado em relação as métricas Precisão, Recall, F1 e mAP para todas as classes e para cada uma separadamente. Os valores dessas métricas são apresentados na Tabela 5.

**Tabela 5** – Resultado da validação da rede YOLOv7.

Classe	Imagens	Rótulos	Precisão	Recall	F1-score	mAP@.5
<b>Todas</b>	53	818	0,94	0,82	0,87	0,90
<b>Maduro</b>	53	633	0,98	0,91	0,95	0,99
<b>Demasiado maduro</b>	53	119	0,96	0,62	0,75	0,80
<b>Não maduro</b>	53	66	0,87	0,92	0,90	0,92

Fonte: Do autor (2023).

A rede Yolov7 apresentou valores de 90% para mAP, 87% de F1, 0,82 de recall e 94% de precisão para o conjunto de dados utilizado. Os valores de F1 para as classes foi de 95% para



frutos maduros, 75% para os frutos demasiados maduros e 90% para os frutos não maduros. Em estudo similar, Bazame et al. (2021) utilizaram o modelo YOLOv3-tiny que apresentou mAP de 84%, F1-Score de 82%, precisão de 83% e recall de 82%. Os resultados desse trabalho indicam que os constantes desenvolvimentos e atualizações da rede YOLO têm resultado em uma a melhor performance da rede.


A rede YOLOv1 apresentava baixos valores de recall, em sua próxima versão houve a melhora do problema de sobre ajuste adicionando uma técnica de normalização em lote reduzido, já o modelo YOLOv3 passou a utilizar a rede neural convolucional Darknet 53 como extrator de características na parte *backbone*, e no modelo v4 foi incorporado a CSP Darknet53 (DIWAN; ANIRUDH; TEMBHURNE, 2023; NOMAN et al., 2023). O YOLOv5 na parte *backbone* utiliza uma estrutura de foco com módulos CSP que mescla características da imagem para solucionar o problema de detecção em multiescala (PÉREZ-PORRAS et al., 2022). Por fim, no modelo YOLOv7 adota estratégias de dimensionamento com base em concatenação, reparametrização de convolução e os exclusivos EELAN, obtendo um bom balanço entre eficiência de detecção e precisão (LAI et al., 2023). Ainda a estrutura piramidal melhorando a capacidade de detecção.

Yaun (2023) utilizou o Yolov7 como representante de última geração de detectores de objeto e o YOLOv4 como uma base de referência. O objeto de classificação foi botão de flor de maçã em que foram testados diferentes tamanhos de base de dados para treinamento da rede. Os resultados demonstraram que o YOLOv7 necessita de menor quantidade de imagens anotadas para atingir precisão similar ao YOLOv4. Chen et al. (2022a) utilizaram o modelo YOLOv7 para detecção de citrus em pomar. Os resultados demonstraram que a rede pode ser uma alternativa com rápida e precisa detecção, além de ser um modelo leve para ser implementado. A rede YOLOv7 com algumas modificações, passou de um F1-score de 92,54% para 93,81%. E mesmo sem modificações, o modelo YOLOv7 apresentou melhor desempenho que outros modelos como o Faster RCNN, RetinaNet e SDD. Além de maiores valores de precisão, o modelo se destacou pela rapidez de processamento. Essencial para ser utilizado em sistema de coleta e processamento de dados em tempo real.

As informações de saída do modelo YOLOv7 são basicamente compostas de duas partes: imagem de localização dos frutos de café com identificação e probabilidade da classe de maturação. Exemplos de imagens utilizadas na validação são apresentadas na Figura 23. A Figura 23 apresenta imagens resultantes da validação realizada com a rede YOLOv7. As Figuras 23a e 23b são as imagens originais e as Figuras 23c e 23d são os resultados da

classificação para os graus de maturação conforme as classes não maduro, maduro e demasiado maduro.

**Figura 24** – Imagens resultantes da validação. (a) e (b) são imagens originais, (c) e (d) são os resultados da classificação do grau de maturação dos frutos.



Fonte: Do autor (2023).

Os resultados da classificação dos frutos para as três classes obtidos nessa tese foram comparados com resultados obtidos na literatura, analisando vantagens e limitações do sistema proposto. Os valores de F1-score foram de 90%, 95% e 75% para as classes não maduro, maduro e demasiado maduro, respectivamente. O estudo de Bazame et al. (2021) obteve valores de precisão média de 86.0%, 85.0%, 80.0% para as classes não maduro, maduro e demasiado maduro, respectivamente.

Os resultados mais baixos observados de F1-score para a classe de frutos demasiado maduros são evidenciados no comportamento do parâmetro recall durante o treinamento (Figura 21), que demonstra a dificuldade da rede em identificar esses frutos nas imagens. O fundo da esteira acumula impurezas durante o processo de colheita e dificulta a identificação desse

tipo de fruto. Possivelmente essa condição pode ser amenizada com uma melhor dissipação da iluminação. Uma vez que não é possível alterar a esteira e é muito difícil evitar o acúmulo de impurezas sobre a mesma.

Na Figura 23d é possível observar um erro de classificação em relação a classe de frutos não maduros. Esse erro pode ter ocorrido devido ao baixo número de frutos não maduros presentes no banco de dados. A contagem dos frutos realizada para avaliação do algoritmo de visão computacional (Tabela 2), evidencia essa baixa quantidade de frutos não maduros. Assim, a rede não tem um bom número de representantes dessa classe para extrair características e detectá-los com maior precisão. A rede YOLOv7 necessita de 1000 a 2000 objetos de treinamento para cada classe para garantir o desempenho do modelo em conjunto de dados agrícolas (YUAN, 2023). No entanto, existem fatores que podem influenciar na maturação dos frutos como clima, data da colheita, padronização da lavoura e dentre outros fatores. O conjunto de dados usado no treinamento do modelo apresentou baixo número de frutos não maduros. Para elevar o número de frutos dessa classe seria necessário um número muito grande de imagens para treinamento, e essa é a tarefa que mais demanda tempo. Uma alternativa para trabalhos futuros é utilizar técnicas para aumento de dados (do inglês *data augmentation*). Os frutos maduros foram classificados com maior êxito, o maior número para treinamento permite à rede maior capacidade de generalização dessa classe.

Além disso, o contraste de cor em relação a esteira auxilia na detecção de frutos não maduros e maduros. Diferentemente do observado em relação aos frutos demasiados maduros. Bazame et al. (2021) utilizaram um fundo branco na bica de descarga. É provável que durante a colheita e dependendo das condições dos frutos de café esse fundo passe a acumular impurezas. Possivelmente, uma melhor forma de contornar esse problema é com iluminação com maior intensidade, difusa e uniforme. Permitindo identificar nas imagens o contorno dos frutos com maior facilidade. Assim, imagens de melhor qualidade colaboram com a capacidade de detecção e classificação da rede. Também modificações na estrutura original da rede YOLOv7 podem ser implementadas futuramente para obter melhores resultados de classificação. Lai et al. (2023) incorporou módulos de atenção para melhorar a detecção de abacaxis. Segundo os autores essa modificação pode ser utilizada em imagens com fundos complexos, assim a rede atribui pesos diferentes aos dados de entrada da rede para permitir que o modelo descarte informações irrelevantes e utilize mais informações relevantes.

Os resultados de classificação realizada pela rede YOLOv7 foram superiores ao do algoritmo desenvolvido quando comparado as métricas. Redes neurais convolucionais são capazes de extrair diversas características para realizar a classificação de um grande banco de

dados. Isso permite que esse tipo de processamento tenha alta capacidade de generalização, podendo produzir resultados melhores quando comparados com a aplicação de técnicas de visão computacional. Lin et al. (2018) comparou modelos de aprendizado profundo e as abordagens tradicionais para classificação de grãos de arroz. Aprendizado profundo atingiu 95,5% de precisão e com abordagens tradicionais, os valores variaram de 89,1% a 92,1%. No entanto, técnicas de processamento de imagem podem ser utilizadas em combinação com rede YOLO. Salvucci et al. (2022) desenvolveram um sistema que utiliza técnicas de visão computacional para realizar o pré-processamento das imagens de entrada na rede YOLOv3-tiny obtendo acurácia acima de 95%. Os autores apontaram que uma causa de erros importante foram os frutos próximos uns dos outros. Esse problema também foi relatado por Bazame et al. (2021) utilizando o mesmo modelo de rede para classificação de frutos de café. Neste estudo, a rede YOLOv7 foi capaz de classificar os frutos maduros com sobreposição ou parcialmente encobertos (Figura 23c), demonstrando a superioridade do modelo da rede.

A rede YOLOv7 demonstrou promissora capacidade para a detecção de frutos de café e ser utilizada em sistemas embarcados. As informações de maturação dos frutos podem ser utilizadas futuramente para o ajuste da colhedora durante o processo de colheita. Auxiliando no controle da velocidade de deslocamento e intensidade de vibração nas varetas. Essas informações, juntamente com regulagens adequadas da colhedora, devem contribuir para melhorar a eficiência de colheita (SANTINATO et al., 2014; VELLOSO et al., 2020).

## **5. CONCLUSÕES**

A precisão média do algoritmo desenvolvido foi de 72% e 70% para os graus de maturação não maduro e maduro. Não foi possível realizar a classificação de frutos demasiados maduros com o algoritmo proposto devido à baixa diferenciação destes com a esteira da colhedora.

A rede YOLOv7 apresentou os valores de F1-score de 90%, 95% e 75% para as classes não maduro, maduro e demasiado maduro, respectivamente.

## **6. CONSIDERAÇÕES FINAIS**

Os resultados apresentados podem contribuir para o desenvolvimento de programa computacional para identificação e classificação quanto a maturação de frutos de café. Além disso, trabalhos futuros podem testar modificações na estrutura original da rede, como incorporar mecanismos de atenção, para melhorar a classificação de frutos de café.

## 7. REFERÊNCIAS

- AZARMDEL, H. et al. Evaluation of image processing technique as an expert system in mulberry fruit grading based on ripeness level using artificial neural networks (ANNs) and support vector machine (SVM). **Postharvest Biology and Technology**, v. 166, n. December 2019, p. 111201, 2020.
- BARGOTI, S.; UNDERWOOD, J. Deep fruit detection in orchards. **Proceedings - IEEE International Conference on Robotics and Automation**, n. October, p. 3626–3633, 2017a.
- BARGOTI, S.; UNDERWOOD, J. P. Image Segmentation for Fruit Detection and Yield Estimation in Apple Orchards. **Journal of Field Robotics**, v. 34, n. 6, p. 1039–1060, 2017b.
- BARROS, M. M. DE et al. Use of classifier to determine coffee harvest time by detachment force. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 5, p. 366–370, 2018.
- BAZAME, H. C. et al. Detection, classification, and mapping of coffee fruits during harvest with computer vision. **Computers and Electronics in Agriculture**, v. 183, n. February, 2021.
- BAZAME, H. C. et al. Detection of coffee fruits on tree branches using computer vision. **Scientia Agrícola**, v. 80, 2022.
- BECHAR, A.; VIGNEAULT, C. Agricultural robots for field operations: Concepts and components. **Biosystems Engineering**, v. 149, p. 94–111, 2016.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. 22 abr. 2020.
- CHEN, J. et al. Using deep transfer learning for image-based plant disease identification. **Computers and Electronics in Agriculture**, v. 173, n. March, p. 105393, 2020.
- CHEN, J. et al. A Multiscale Lightweight and Efficient Model Based on YOLOv7: Applied to Citrus Orchard. **Plants**, v. 11, n. 23, 1 dez. 2022a.
- CHEN, J. et al. Research on YOLOv7-based defect detection method for automotive running lights. **Systems Science & Control Engineering**, v. 11, n. 1, 31 dez. 2023.
- CHEN, W. et al. CitrusYOLO: A Algorithm for Citrus Detection under Orchard Environment Based on YOLOv4. **Multimedia Tools and Applications**, v. 81, n. 22, p. 31363–31389, 1 set. 2022b.
- CHINCHULUUN, R.; LEE, W. S.; EHSANI, R. Citrus yield mapping system on a canopy shake and catch harvester. **2007 ASABE Annual International Meeting, Technical Papers**, v. 7 BOOK, n. January 2002, 2007.
- COELHO, A. L. DE F. et al. Dynamic behavior of the coffee fruit-stem-branch system using stochastic finite element method. **Coffee Science**, v. 11, n. 1, p. 1–10, 2016.
- CONAB. **Acompanhamento da safra brasileira de café - 3º levantamento**. 9. ed. Brasília: CONAB, 2022. v. 3

CUNHA, J. P. B. et al. Economic viability for different coffee harvest systems. **Coffee Science**, v. 11, n. 3, p. 416–425, 2016.

DAMATTA, F. M.; RAMALHO, J. D. C. Impacts of drought and temperature stress on coffee. **Brazilian Journal of Plant Physiology**, v. 18, n. 1, p. 55–81, 2006.

DE CAMARGO, Â. P.; DE CAMARGO, M. B. P. Definição e Esquematização das Fases Fenológicas do Cafeeiro Arábica nas Condições Tropicais do Brasil. **Bragantia**, v. 60, n. 1, p. 65–68, 2001.

DING, X. et al. RepVGG: Making VGG-style ConvNets Great Again. **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition**, p. 13733–13742, 10 jan. 2021.

DIWAN, T.; ANIRUDH, G.; TEMBHURNE, J. V. Object detection using YOLO: challenges, architectural successors, datasets and applications. **Multimedia Tools and Applications**, v. 82, n. 6, p. 9243–9275, 1 mar. 2023.

DORJ, U. O.; LEE, M.; YUN, S. SEOK. An yield estimation in citrus orchards via fruit detection and counting using image processing. **Computers and Electronics in Agriculture**, v. 140, p. 103–112, 2017.

FERRAZ, G. A. E S. et al. Geostatistical analysis of fruit yield and detachment force in coffee. **Precision Agriculture**, v. 13, n. 1, p. 76–89, 2012.

FERREIRA JÚNIOR, L. D. G.; DA SILVA, F. M.; FERREIRA, D. D. Displacement Tracking of Harvester Rods of a Coffee Harvester. **IEEE Latin America Transactions**, v. 14, n. 12, p. 4674–4680, 2016.

FERREIRA JÚNIOR, L. DE G. et al. Recomendação para colheita mecânica do café baseado no comportamento de vibração das hastes derriçadoras. **Ciência Rural**, v. 46, n. 2, p. 273–278, 2016.

FERREIRA JÚNIOR, L. DE G. et al. Characterization of the coffee fruit detachment force in crop subjected to mechanized harvesting. **Coffee Science**, v. 13, n. 1, p. 71–79, 2018.

FERREIRA JÚNIOR, L. DE G. et al. Dynamic behavior of coffee tree branches during mechanical harvest. **Computers and Electronics in Agriculture**, v. 173, n. October 2019, p. 105415, 2020.

GARCIA-LAMONT, F. et al. Segmentation of images by color features: A survey. **Neurocomputing**, v. 292, p. 1–27, 2018.

GOMES, E. Q. et al. Transmissibility of coffee fruit-peduncle-branch systems submitted to vibration induced by impact. **DYNA**, v. 87, n. 214, p. 61–65, 2020.

HAMZA, R.; CHTOUROU, M. **Apple ripeness estimation using artificial neural network**. Proceedings - 2018 International Conference on High Performance Computing and Simulation, HPCS 2018. **Anais...IEEE**, 2018.

- HÄNI, N.; ROY, P.; ISLER, V. A comparative study of fruit detection and counting methods for yield mapping in apple orchards. **Journal of Field Robotics**, v. 37, n. 2, p. 263–282, 2020.
- HE, K. et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. **Springer International Publishing**, p. 346–361, 18 jun. 2014.
- HUSSAIN, M. et al. Domain Feature Mapping with YOLOv7 for Automated Edge-Based Pallet Racking Inspections. **Sensors**, v. 22, n. 18, 1 set. 2022.
- JACINTHO, J. L. et al. Management zones in coffee cultivation. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 2, p. 94–99, 2017.
- JIANG, K. et al. An Attention Mechanism-Improved YOLOv7 Object Detection Algorithm for Hemp Duck Count Estimation. **Agriculture (Switzerland)**, v. 12, n. 10, 1 out. 2022.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, n. February, p. 70–90, 2018.
- KANG, H.; ZHOU, H.; CHEN, C. Visual perception and modeling for autonomous apple harvesting. **IEEE Access**, v. 8, p. 62151–62163, 2020.
- KAO, I. H. et al. Determination of Lycopersicon maturity using convolutional autoencoders. **Scientia Horticulturae**, v. 256, n. May, p. 108538, 2019.
- KAZAMA, E. H. **Colheita de prescrição para o café, é possível?** [s.l.] UNIVERSIDADE ESTADUAL PAULISTA - UNESP, 2019.
- KAZAMA, E. H. et al. Methodology for selective coffee harvesting in management zones of yield and maturation. **Precision Agriculture**, n. 0123456789, 2020.
- KHEIRALIPOUR, K.; NADIMI, M.; PALIWAL, J. Development of an Intelligent Imaging System for Ripeness Determination of Wild Pistachios. **Sensors**, v. 22, n. 19, 1 out. 2022.
- KHOJASTEHNAZHAND, M.; MOHAMMADI, V.; MINAEI, S. Maturity detection and volume estimation of apricot using image processing technique. **Scientia Horticulturae**, v. 251, n. January, p. 247–251, 2019.
- KIRK, R.; CIELNIAK, G.; MANGAN, M. L\*a\*b\*Fruits: A rapid and robust outdoor fruit detection system combining bio-inspired features with one-stage deep learning networks. **Sensors (Switzerland)**, v. 20, n. 1, p. 1–19, 2020.
- KOIRALA, A. et al. Deep learning – Method overview and review of use for fruit detection and yield estimation. **Computers and Electronics in Agriculture**, v. 162, n. April, p. 219–234, 2019.
- LAI, Y. et al. A Pineapple Target Detection Method in a Field Environment Based on Improved YOLOv7. **Applied Sciences (Switzerland)**, v. 13, n. 4, 1 fev. 2023.
- LANNA, G. B. M.; REIS, R. P. Influência Da Mecanização Da Colheita na Viabilidade Econômicofinanceira da Cafeicultura No Sul de Minas Gerais. **Coffee Science**, v. 7, n. 2, p. 110–121, 2012.



LIMA, L. C. DE et al. Crescimento e produtividade do cafeeiro irrigado, em função de diferentes fontes de nitrogênio. **Coffee Science**, v. 11, n. 1, p. 97–107, 2016.

LIN, G. et al. Color-, depth-, and shape-based 3D fruit detection. **Precision Agriculture**, v. 21, n. 1, p. 1–17, 2020.

LIN, T.-Y. et al. **Microsoft COCO: Common Objects in Context**. (D. Fleet, T. Pajdla, B. T. T. Schiele, Eds.)Computer Vision–ECCV 2014: 13th European Conference. **Anais...Zurich, Suíça: Springer International Publishing**, set. 2014. Disponível em: <<http://arxiv.org/abs/1405.0312>>

LIN, T.-Y. et al. Focal Loss for Dense Object Detection. **Proceedings of the IEEE international conference on computer vision**, p. 2980–2988, 7 ago. 2017.

LIU, K. et al. Underwater Target Detection Based on Improved YOLOv7. **Journal of Marine Science and Engineering**, v. 11, n. 3, p. 677, 22 mar. 2023.

LIU WEI AND ANGUELOV, D. AND E. D. AND S. C. AND R. S. AND F. C.-Y. AND B. A. C. **SSD: Single Shot MultiBox Detector**. (J. and S. N. and W. M. Leibe Bastian and Matas, Ed.)Computer Vision – ECCV 2016. **Anais...Cham: Springer International Publishing**, 2016.

LOPEZ, J. J.; COBOS, M.; AGUILERA, E. Computer-based detection and classification of flaws in citrus fruits. **Neural Computing and Applications**, v. 20, n. 7, p. 975–981, 2011.

MACEACHERN, C. B. et al. Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks. **Smart Agricultural Technology**, v. 3, 1 fev. 2023.

MAO, S. et al. Automatic cucumber recognition algorithm for harvesting robots in the natural environment using deep learning and multi-feature fusion. **Computers and Electronics in Agriculture**, v. 170, n. January, p. 105254, 2020.

MAZEN, F. M. A.; NASHAT, A. A. Ripeness Classification of Bananas Using an Artificial Neural Network. **Arabian Journal for Science and Engineering**, v. 44, n. 8, p. 6901–6910, 2019.

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

MIRAEI ASHTIANI, S. H. et al. Detection of mulberry ripeness stages using deep learning models. **IEEE Access**, v. 9, p. 100380–100394, 2021.

MIRANDA, F. R.; DRUMOND, L. C. D.; RONCHI, C. P. Synchronizing coffee blossoming and fruit ripening in irrigated crops of the Brazilian Cerrado Mineiro Region. **Australian Journal of Crop Science**, v. 14, n. 4, p. 605–613, 2020.

NAIK, S.; PATEL, B. Machine Vision based Fruit Classification and Grading - A Review. **International Journal of Computer Applications**, v. 170, n. 9, p. 22–34, 2017.

NOMAN, M. K. et al. Improving accuracy and efficiency in seagrass detection using state-of-the-art AI techniques. **Ecological Informatics**, p. 102047, set. 2023.

ORTENZI, L. et al. A machine vision rapid method to determine the ripeness degree of olive lots. **Sensors**, v. 21, n. 9, 1 maio 2021.

PEREIRA, S. P. et al. Crescimento, produtividade e bienalidade do cafeeiro em função do espaçamento de cultivo. **Pesquisa Agropecuaria Brasileira**, v. 46, n. 2, p. 152–160, 2011.

PÉREZ-PORRAS, F. J. et al. Early and on-ground image-based detection of poppy (*Papaver rhoeas*) in wheat using YOLO architectures. **Weed Science**, 15 jan. 2022.

PINTO, C. et al. Classification of Green coffee bean images basec on defect types using convolutional neural network (CNN). **Proceedings - 2017 International Conference on Advanced Informatics: Concepts, Theory and Applications, ICAICTA 2017**, 2017.

QIU, Y. et al. IDOD-YOLOV7: Image-Dehazing YOLOV7 for Object Detection in Low-Light Foggy Traffic Environments. **Sensors**, v. 23, n. 3, 1 fev. 2023.

RAMOS, P. J. et al. Automatic fruit count on coffee branches using computer vision. **Computers and Electronics in Agriculture**, v. 137, p. 9–22, 2017.

RAMOS, P. J.; AVENDAÑO, J.; PRIETO, F. A. Measurement of the ripening rate on coffee branches by using 3D images in outdoor environments. **Computers in Industry**, v. 99, n. August 2017, p. 83–95, 2018.

REDMON, J. et al. **You Only Look Once: Unified, Real-Time Object Detection**. Proceedings of the IEEE conference on computer vision and pattern recognition. **Anais...8** jun. 2016. Disponível em: <<http://arxiv.org/abs/1506.02640>>

REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. **arXiv**, p. 1–6, 8 abr. 2018.

RODRÍGUEZ-PULIDO, F. J. et al. Ripeness estimation of grape berries and seeds by image analysis. **Computers and Electronics in Agriculture**, v. 82, p. 128–133, 2012.

SALVUCCI, G. et al. Fast olive quality assessment through RGB images and advanced convolutional neural network modeling. **European Food Research and Technology**, v. 248, n. 5, p. 1395–1405, 1 maio 2022.

SANTANA, L. S. et al. Identification and Counting of Coffee Trees Based on Convolutional Neural Network Applied to RGB Images Obtained by RPA. **Sustainability (Switzerland)**, v. 15, n. 1, 1 jan. 2023.

SANTINATO, F. et al. Análise quali-quantitativa da operação de colheita mecanizada de café em duas safras. **Coffee Science**, v. 9, n. 4, p. 495–505, 2014.

SANTINATO, F. et al. Número de operações mecanizadas na colheita do café. **Ciência Rural**, v. 45, n. 10, p. 1809–1814, 2015.

SANTINATO, F. et al. Mechanical harvesting of Coffee in high slope. **Revista Caatinga**, v. 29, n. 3, p. 685–691, 2016.

SANTINATO, F. et al. Morphological and productive influence of harvest on coffee plants. **Australian Journal of Crop Science**, v. 13, n. 1, p. 144–150, 2019a.

SANTINATO, F. et al. Operational cost of mechanized harvesting of first-crop coffee. **Australian Journal of Crop Science**, v. 13, n. 9, p. 1503–1510, 2019b.

SARTORI, S. et al. **Mapping the spatial variability of coffee yield with mechanical harvester**. World Congress of Computers in Agriculture and Natural Resources, Proceedings of the 2002 Conference. **Anais...2002**.

SILVA, F. C. DA et al. Comportamento da força de desprendimento dos frutos de cafeeiros ao longo do período de colheita. **Ciência e Agrotecnologia**, v. 34, n. 2, p. 468–474, 2010.

SILVA, F. C. DA et al. Desempenho operacional da colheita mecanizada e seletiva do café em função da força de desprendimento dos frutos. **Coffee Science**, v. 8, n. 1, p. 53–60, 2013a.

SILVA, F. M. DA et al. Uso de ethrel na colheita mecanizada e seletiva de café arábica (*Coffea arabica* L.). **Coffee Science**, v. 4, n. 2, p. 178–182, 2009.

SILVA, F. M. DA et al. **Desempenho e influência da colhedora mecanizada Nna produtividade da lavoura cafeeira em quatro safras**. VIII Simpósio de Pesquisa dos Cafés do Brasi. **Anais...2013b**.

SILVA, F. C. et al. Efficiency of coffee mechanical and selective harvesting in different vibration during harvest time. **Coffee Science**, v. 10, n. 1, p. 56–64, 2015.

SILVA, F. C. et al. Correlação da força de desprendimento dos frutos em cafeeiros sob diferentes condições nutricionais. **Coffee Science**, v. 11, n. 2, p. 169–179, 2016.

SILVA, F. M. et al. Viabilidade técnica e econômica da colheita mecanizada do café. **Visão Agrícola**, v. 13, p. 98–101, 2013c.

SOLOMON, C.; BREACKON, T. **Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em Matlab**. 1. ed. Rio de Janeiro: [s.n.].

TAVARES, T. D. O. et al. The times, movements and operational efficiency of mechanized coffee harvesting in sloped areas. **PLoS ONE**, v. 14, n. 5, p. 1–10, 2019.

TEIXEIRA, A. L. F. et al. A moderna cafeicultura dos cerrados brasileiros. **Pesq. Agropec. Trop**, v. 42, n. 2, p. 231–240, 2012.

TKACHENKO, M. et al. Label studio: data labeling software, 2020-2022. **Open source software available from GitHub**, 2022.

VELLOSO, N. S. et al. Modal properties of coffee plants via numerical simulation. **Computers and Electronics in Agriculture**, v. 175, n. July, p. 105552, 2020.

VILELA, P.; RUFINO, J. **Caracterização da cafeicultura de montanha de Minas Gerais**. [s.l.: s.n.]. v. I

VILLIBOR, G. P. et al. Determinação das propriedades modais do sistema fruto-pedúnculo do café por vídeos de alta velocidade e processamento de imagens digitais. **Acta Scientiarum - Technology**, v. 38, n. 1, p. 41–48, 2016.

WAN, P. et al. A methodology for fresh tomato maturity detection using computer vision. **Computers and Electronics in Agriculture**, v. 146, n. February, p. 43–50, 2018.

WANG, C.-Y. et al. CSPNet: A New Backbone that can Enhance Learning Capability of CNN. 26 nov. 2019.

WANG, C.-Y.; BOCHKOVSKIY, A.; LIAO, H.-Y. M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. **arXiv preprint arXiv:2207.02696**, p. 1–15, 6 jul. 2022.

YUAN, W. Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification. **AgriEngineering**, v. 5, n. 1, p. 413–424, 20 fev. 2023.

ZABAWA, L. et al. Counting of grapevine berries in images via semantic segmentation using convolutional neural networks. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 164, n. March, p. 73–83, 2020.

ZAIDNER, G.; SHAPIRO, A. A novel data fusion algorithm for low-cost localisation and navigation of autonomous vineyard sprayer robots. **Biosystems Engineering**, v. 146, p. 133–148, 2016.

ZHAO, R. et al. Low-rank-constraint-based machine vision algorithm for chaffer-sieve-clogging recognition of corn harvester. **Computers and Electronics in Agriculture**, v. 198, 1 jul. 2022.

ZHUANG, J. et al. Assessment of external properties for identifying banana fruit maturity stages using optical imaging techniques. **Sensors (Switzerland)**, v. 19, n. 13, 2019.