



APLICAÇÃO DE TÉCNICAS DE VISÃO COMPUTACIONAL PARA DETERMINAÇÃO DO NÍVEL DE MATURAÇÃO DO CAFÉ

Andressa Caroline Lopes de Assis⁽¹⁾, Daniel Reis Gonçalves Sant'ana⁽²⁾, Marcos Roberto Ribeiro⁽³⁾

⁽¹⁾Bolsista FAPEMIG, Graduanda em Engenharia de Computação, Instituto Federal de Minas Gerais (IFMG) – Campus Bambuí; *andressacaroline082011@gmail.com*

⁽²⁾Voluntário, Graduando em Engenharia de Computação, Instituto Federal de Minas Gerais (IFMG) – Campus Bambuí; *drgsantaana@gmail.com*

⁽³⁾Professor Orientador – IFMG – Campus Bambuí; *marcos.ribeiro@ifmg.edu.br*

RESUMO

O Brasil é o maior produtor e segundo maior consumidor de café no mundo. Assim, o setor cafeeiro está sempre em busca de novas tecnologias que possam trazer mais facilidade, agilidade e qualidade para o produto. Um fator crucial para a qualidade do café é determinação do melhor momento para fazer a colheita que deve coincidir com a maior porcentagem de grãos maduros na lavoura. Uma das maneiras de determinar o grau de maturação dos frutos é por meio de uma amostragem com colheita e contagem manual. Esse método é trabalhoso e pode levar a uma informação imprecisa. O presente trabalho teve como objetivo analisar e verificar a eficácia de técnicas de Visão Computacional para determinar o grau de maturação do café com base em fotos dos frutos na lavoura. Foram treinados e validados modelos de inteligência artificial baseados no RT-DETR utilizando uma base de dados de fotos com frutos de café previamente anotados. Os experimentos de validações mostraram que o modelo R50VD apresentou os melhores resultados.

Palavras-chave: Ponto de Colheita do Café; Visão Computacional; Inteligência Artificial.

1 INTRODUÇÃO

O Brasil é o maior produtor e o segundo maior consumidor de café mundialmente, o que estimula a adoção de tecnologias que aumentem a eficiência e a qualidade da produção cafeeira (ABIC, 2023). Entre essas tecnologias, a Visão Computacional tem se destacado como uma ferramenta que possibilita a análise automatizada das características dos grãos de café, como cor, forma e tamanho, auxiliando no monitoramento do ponto ideal de colheita (BAZAME *et al.*, 2022; RODRIGUES, 2022).

A qualidade do café depende de várias etapas, desde o cultivo até a preparação da bebida, sendo o ponto de colheita uma fase essencial para o produto final. O ponto ideal de colheita ocorre quando a lavoura possui predominantemente frutos maduros, minimizando a presença de grãos verdes ou secos, o que favorece a qualidade final do produto (RIBEIRO *et al.*, 2021;



FONSECA *et al.*, 2015; CHALFOUN; CARVALHO, 1997). Tradicionalmente, a identificação deste ponto é feita por amostragem manual, um método que exige esforço físico e apresenta imprecisões (MATIELLO *et al.*, 2005).

Este trabalho teve como objetivo desenvolver um modelo de inteligência artificial em Visão Computacional para estimar o grau de maturação dos grãos de café com base em fotos. Diversos modelos foram treinados com imagens coletadas diretamente das lavouras e, após o treinamento, foram validados para identificar o modelo com o melhor desempenho.

2 METODOLOGIA

A primeira etapa no desenvolvimento deste trabalho foi a construção de uma base de dados com fotos de grãos de café em diferentes estágios de maturação. As imagens passaram por um processo de anotação para marcar os frutos de café, utilizando o formato *Common Objects in Context* (COCO) e o software Makesense.ai¹ (LIN *et al.*, 2014). Inicialmente, foi escolhido o método de anotação em polígonos para capturar regiões com vários frutos. No entanto, mesmo após a conversão das anotações, não foi possível treinar os modelos de inteligência artificial.

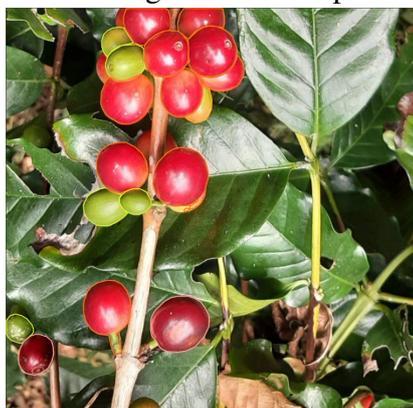
Foi realizada uma busca por novas bases de dados. Nessa busca, foi encontrada a Coffee Fruit Maturity, composta por 859 imagens. A referida base conta com mais de 11 mil anotações individuais nos frutos, no formato de polígono. Nesse caso, foi possível converter as anotações, preservando a identificação individual dos grãos de café. As Figuras 1(a) e 1(b) mostram, respectivamente, uma imagem com a anotação original em formato de polígonos e sua conversão para retângulos.

Com a base de dados preparada, os modelos de inteligência artificial foram treinados utilizando a arquitetura RT-DETR (ZHAO *et al.*, 2024). Os experimentos foram realizados em um computador pessoal equipado com processador Intel Core i7-11700, 16 GB de memória RAM e placa de vídeo Nvidia GeForce RTX 3070 com 8 GB de memória. Para avaliar o desempenho dos modelos, os dados foram divididos em 70% para treinamento e 30% para validação, com divisão aleatória (semente 42).

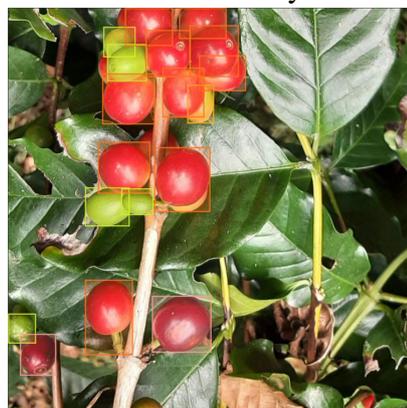
Durante o treinamento, utilizou-se a métrica de erro *Generalized Intersection over Union* (GIoU), que considera a interseção, a união e a distância entre as caixas preditas e reais. Na fase de validação, foram aplicadas as métricas *Average Precision* (AP) e *Average Recall* (AR). A AP calcula a precisão média do modelo em diferentes limiares de confiança, enquanto a AR mede a capacidade do modelo de detectar corretamente os objetos, considerando várias

¹ <https://www.makesense.ai/>

Figura 1 – Exemplo de anotações na base Coffee Fruit Maturity



(a) Anotação em polígonos



(b) Anotação em retângulos

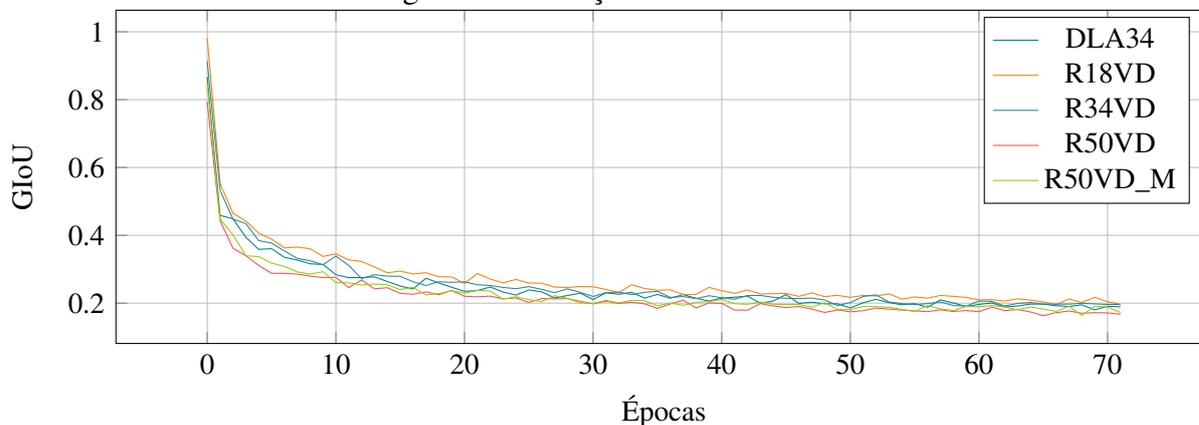
Fonte: Elaborado pelos autores, 2024.

taxas de interseção *Intersection over Union* (IoU) entre caixas preditas e reais. Os limiares de confiança variaram de 0,5 a 0,95.

3 RESULTADOS E DISCUSSÕES

Foram testados cinco dos seis modelos RT-DETR disponíveis. O modelo R101VD, com 76 milhões de parâmetros, não pôde ser treinado porque a memória na GPU não foi suficiente. A Figura 2 mostra a evolução do treinamento dos modelos testados. É possível observar que o erro (GIoU) cai conforme o número de épocas aumenta, atingindo um limiar aceitável em 72 épocas.

Figura 2 – Evolução do treinamento



Fonte: Elaborado pelos autores, 2024.



A Tabela 1 mostra os resultados de validação dos modelos com seus respectivos números de parâmetros. Quanto maior o número de parâmetros, mais complexo e mais pesado é o treinamento. Por outro lado, é possível observar que os modelos mais complexos apresentam melhores resultados nas medidas de AP e AR. Os resultados indicam que o modelo R50VD apresentou o melhor desempenho geral entre os modelos avaliados. Embora o treinamento com o modelo R101VD não tenha sido possível devido a limitações de hardware, os modelos testados são capazes de detectar os frutos de café nas fotos.

Tabela 1 – Avaliação dos modelos

Modelo	Parâmetros (milhões)	AP	AR
R18VD	20	0.603	0.917
R34VD	31	0.614	0.929
DLA34	34	0.607	0.934
R50VD_M	36	0.660	0.930
R50VD	42	0.669	0.938

Fonte: Elaborado pelos autores, 2024.

4 CONCLUSÕES

O presente trabalho buscou facilitar a identificação do ponto ideal de colheita do café por meio de fotos. Foi preparada uma base de dados com imagens de diferentes estágios de maturação dos frutos. Foram treinados e validados modelos de inteligência artificial baseados no RT-DETR. Os experimentos de validação mostraram que o modelo R50VD apresentou os melhores resultados.

Com a conclusão do presente trabalho, algumas possibilidades de trabalhos futuros interessantes podem ser elencadas. Como forma de aprimorar a precisão e aplicabilidade, técnicas de processamento digital de imagem podem ser usadas para analisar as regiões identificadas, determinando automaticamente o grau de maturação do café. Além disso, a integração da inteligência artificial desenvolvida com *drones* e dispositivos móveis pode dar origem a tecnologias promissoras para análise do grau de maturação de café de forma prática.

Agradecimentos: Os autores agradecem à FAPEMIG pela concessão de bolsa e ao IFMG por viabilizar o desenvolvimento do projeto.



REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE CAFÉ (ABIC). **O café brasileiro na atualidade**. 2023. Disponível em:

<https://www.abic.com.br/tudo-de-cafe/o-cafe-brasileiro-na-atualidade/>. Acesso em: 24/12/2023.

BAZAME, H. C. *et al.* Mapping coffee yield with computer vision. **Precision Agriculture**, Springer, v. 23, p. 2372–2387, 2022. Disponível em:

<https://doi.org/10.1007/s11119-022-09924-0>. Acesso em: 15/02/2023.

CHALFOUN, S. M.; CARVALHO, V. D. d. **Colheita e preparo do café**. Lavras: UFLA/FAEPE, 1997.

FONSECA, H. D. M. *et al.* Avaliação quantitativa e qualitativa do café (*Coffea arábica* L.) em função dos diferentes graus de maturação na época da colheita. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL (SPCB), IX., 2015, Curitiba. **Anais [...]** 2015. p. 755–760.

Disponível em: <http://www.sbicafe.ufv.br/handle/123456789/3533>. Acesso em: 25/01/2023.

LIN, T.-Y. *et al.* Microsoft COCO: Common Objects in Context. In: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), XIII., 2014, Zurich. **Proceedings [...]** 2014. p. 740–755. Disponível em: https://doi.org/10.1007/978-3-319-10602-1_48. Acesso em: 25/08/2024.

MATIELLO, J. B. *et al.* **Cultura de café no Brasil**: Novo manual de recomendações. Brasília, 2005.

RIBEIRO, I. Y. L. *et al.* Classificação de frutos de café (*coffea arabica*) em função dos diferentes graus de maturação na época de colheita no município de Itaquiraí-MS. In: ENCONTRO INTERNACIONAL DE GESTÃO, DESENVOLVIMENTO E INOVAÇÃO (EIGEDIN), V., 2021, *online*. **Anais [...]** UFMS, 2021. Disponível em:

<https://periodicos.ufms.br/index.php/EIGEDIN/article/view/14240>.

RODRIGUES, J. V. V. **CoffeColor**: desenvolvimento de um aplicativo para detecção do grau de torra de café baseado na cor. 2022. Trabalho de Conclusão de Curso (Graduação em Engenharia de Computação) – Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG), Bambuí, 2022.

ZHAO, Y. *et al.* DETRs Beat YOLOs on Real-time Object Detection. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), XVII., 2024, Seattle.

Proceedings [...] 2024. p. 16965–16974. Disponível em:

https://openaccess.thecvf.com/content/CVPR2024/html/Zhao_DETRs_Beat_YOLOs_on_Real-time_Object_Detection_CVPR_2024_paper.html. Acesso em: 25/08/2024.