

YOLOv8 para Controle de Produção Pós-colheita e Beneficiamento de Frutos

Priscila Cathlen Alves Sá¹

 orcid.org/0009-0005-3567-3170

Ana Quezia¹

 orcid.org/0000-0003-4227-0984

Cleber Marcus¹

 orcid.org/0009-0005-0445-9286

Alexandre M. A. Maciel¹

 orcid.org/0000-0003-4348-9291

Carmelo Bastos-Filho¹

 orcid.org/0000-0002-0924-5341

Claudemiro Lima Junior¹

 orcid.org/0000-0002-6640-6340

¹Universidade de Pernambuco (UPE).
Residência Tecnológica.
E-mail: dsaprilasa@gmail.com

DOI: 10.25286/rep.v9i1.2788

Esta obra apresenta Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.

Como citar este artigo pela NBR 6023/2018: Priscila Cathlen Alves Sá; Ana Quezia; Cleber Marcus; Alexandre M. A. Maciel; Carmelo Bastos-Filho; Claudemiro Lima Júnior. YOLOv8 para Controle de Produção Pós-colheita e Beneficiamento de Frutos. Revista de Engenharia e Pesquisa Aplicada, v.9, n. 1, p. 115-122, 2024. DOI: 10.25286/rep.v9i1.2788

RESUMO

Este artigo teve como objetivo avaliar o desempenho do modelo de inteligência artificial YOLOv8 para identificar contentores de frutos em imagens e vídeos. Os resultados mostraram que a rede é capaz de atingir alta precisão, tanto em imagens quanto em vídeos, mesmo em condições adversas. A pesquisa operacional (PO) desempenha um papel fundamental nesse trabalho, pois é utilizada para modelar o problema de negócio, identificado como a ausência de controle, em tempo real, da quantidade de frutos beneficiados e como o monitoramento desses contentores pode fornecer métricas para estimativas essenciais de controle de colheita.

PALAVRAS-CHAVE: Visão Computacional; YOLOv8; Pesquisa Operacional; Modelo de negócio; Análise de Dados.

ABSTRACT

In this research, the performance of the YOLOv8 network in identifying fruit containers through images and videos was evaluated. The results showed that the network can achieve high accuracy in both images and videos, even under adverse conditions. Operational research (OR) plays a fundamental role in this work, as it is used to model the business problem identified as the lack of real-time control over the quantity of fruits being processed. Monitoring containers with harvested fruits can provide metrics for essential harvest control estimates in fruit processing.

KEY-WORDS: Computer Vision; YOLOv8; Operational Research; Business Model; Data Analysis.

1 INTRODUÇÃO

A Visão Computacional (VC) é um campo da Inteligência Artificial (AI) que se concentra em permitir que computadores obtenham e compreendam o mundo visual, e usa vários recursos para alcançar seus objetivos, incluindo: Redes Neurais Convolucionais (CNNs), Aprendizado Supervisionado, Aprendizado Não Supervisionado, Aprendizado Semi-Supervisionado, *Transfer Learning*, Processamento de Linguagem Natural (PLN), Processamento Paralelo e GPU, Algoritmos de Pré-processamento de Imagem, Técnicas de Segmentação de Imagem e Técnicas de Pós-processamento [1]. Ela é uma abordagem de inspeção baseada na análise e processamento de imagens, e oferece uma técnica automatizada, não destrutiva, econômica, rápida e sem contato para determinar os padrões de qualidade e controle em vários setores [2][3][4]. Sua aplicação não visa apenas substituir a inspeção manual, mas também melhorar as habilidades manuais na indústria [5], melhorando a precisão e a repetibilidade [6].

Os sistemas de VC e a tecnologia automática baseada na visão podem determinar de forma rápida e com precisão a qualidade dos produtos agrícolas e alimentares, auxiliando no desenvolvimento de processos totalmente automatizados [7][8], com potencial para futuros avanços em sistemas de imagem combinando múltiplas câmeras [9]. Estes sistemas podem efetivamente inspecionar e detectar doenças perigosas em frutas cítricas, auxiliando na detecção precoce e melhor controle de qualidade [10]. Também são eficazes para inspeção automática de qualidade externa de frutas e vegetais, aumentando o valor de mercado e as preferências dos consumidores [11].

A técnica de detecção de objetos "You Look Only Once" (YOLO) é uma família de modelos de aprendizado de máquina profundo projetados para detecção rápida [12]. Em estudos comparativos, a YOLOv2 e a YOLOv3 demonstraram resultados inferiores a rede Mask R-CNN. Por outro lado, estes modelos demonstram capacidade de detectar, segmentar e rastrear com sucesso os aglomerados de uva em pomares, fornecendo dados valiosos para aplicações agrícolas, como previsão de rendimento e colheita automatizada [13]. Em estudos mais recentes para a detecção de aglomerados de uvas comparou-se o desempenho da YOLOv5 com as redes de detecção, a YOLOv3, a YOLOv4, a Faster

R-CNN e a RetinaNet. O estudo mostrou que o YOLOv5 obteve precisão superior [14, 12].

A YOLOv8 é atualmente considerada o estado da arte para atividades de detecção de múltiplos objetos, com melhor resposta temporal, maior precisão e facilidade de uso [15]. Estas características tornam o YOLOv8 uma excelente escolha para a aplicação [16].

A indústria estudada produz e embala frutas *in natura* e a uva de mesa é seu principal produto. Por ser um produto perecível, as atividades de colheita e pós-colheita devem realizadas de forma célere, devido à sensibilidade das uvas à elevação da temperatura [17]. A qualidade do produto vegetal, uma vez perdida, não pode ser recuperada ao longo da cadeia. Por isso, há esforço para diminuir o período entre a colheita e a comercialização, aumentando o tempo de prateleira desses frutos [18]. Os elos da cadeia de produção dessa indústria incluem etapas de produção, processamento e distribuição [19]. A Figura 1 mostra o fluxograma e a Figura 2 apresenta as etapas de beneficiamento das frutas no processo de forma gráfica.

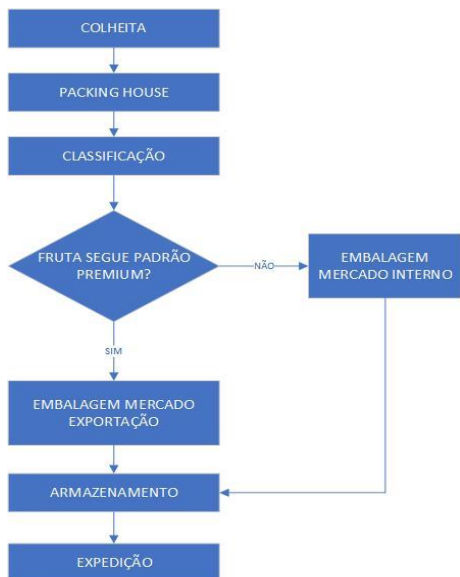
Na etapa de produção, a colheita da uva é realizada manualmente, com pré-seleção dos frutos ainda no campo. São cortados os cachos, retirando-se restos foliares, gavinhas, bagas com danos ou defeitos, imaturas, doentes e desuniformes. Os cachos são colocados em contentores de colheita de plástico e forrados com espuma de polietileno. Em cada contentor, é colocada apenas uma camada de cachos, com os pedúnculos voltados para cima, totalizando o peso médio de 7,5 kg de fruta.

Após a colheita, os contentores são transportados para o local do processamento, onde são separados os cachos de uva de acordo com os seus mercados de destino. A separação é realizada manualmente por embaladeiras. A mensuração e controle de contentores durante sua entrada no processo de beneficiamento de frutas é um processo inteiramente manual na fazenda em estudo e por meio de Pesquisa Operacional (PO) no local de produção, mostrou ser um importante indicador para controle e expedição de produção em tempo real.

Este trabalho objetiva treinar e avaliar o desempenho da rede YOLOv8 para identificar contentores de frutos por meio de imagens e vídeos. Para isso, foram realizadas etapas de planejamento, incluindo a identificação de problemas por meio de Pesquisa Operacional, o levantamento de pré-


requisitos e métricas, e a captação de imagens e vídeos de contentores.

Figura 1 – Fluxograma cadeia de beneficiamento de fruto.



Fonte: autoria própria.

Figura 2 – Etapas de beneficiamento de frutas.



Fonte: autoria própria.

2 DESCRIÇÃO DO PROBLEMA

A identificação de um problema de negócio é essencial para o desenvolvimento de produtos de base tecnológica [20][21]. Existem várias metodologias para identificar problemas, como entrevistas e visitas técnicas ao local de produção [20]. Neste trabalho, foram realizadas entrevistas com trabalhadoras de embalagem e seleção de frutos, líderes técnicos da área de beneficiamento, carregadores e administradores.

Nesta etapa, foi realizado um levantamento de demandas e identificou-se, a partir de uma queixa, que o controle da quantidade de frutos que entravam no *packing house* não era feito em tempo real de forma automatizada ou semiautomatizada. Toda a estimativa era feita de maneira manual e intuitiva. O controle automatizado era realizado

apenas dos produtos que saíam do beneficiamento por meio da tecnologia RFID. Para investigar melhor a questão e verificar se esse problema tinha potencial de ser explorado e trazer resultados positivos para a indústria, optou-se por utilizar uma metodologia de Pesquisa Operacional. A partir da técnica de Programação Linear (LP), foram identificadas as variáveis de decisão (VD), a função objetivo (FO) e as restrições desse problema de produção.

Na usina de beneficiamento estudada, uvas colhidas são recebidas em contentores de 7,5 kg. Em seguida, são encaminhadas para o setor de embalagem, onde são limpas, selecionadas de acordo com o mercado de destino, pesadas, embaladas, acondicionadas em caixas padronizadas de papelão, paletizadas e empilhadas em colunas sobre um palete [22]. Em câmaras frias, as uvas são armazenadas aguardando a última etapa do beneficiamento, a expedição em caminhões climatizados para o mercado consumidor. Todo esse processo visa garantir que as uvas atendam às exigências de mercado final, no caso estudado, os principais clientes são mercados externos [23].

Para atender a demanda de seu mercado, a indústria estabelece como meta diária beneficiar um contêiner de 13 toneladas/dia, com no máximo 6% de refugo. Essa produção para mercados externos recebe a categoria de qualidade “premium”. Já os frutos que não atendem aos critérios físicos exigidos são destinados ao mercado interno. Considerando apenas o cenário objetivo de produção total de frutos colhidos, e sendo a variável de decisão do sistema proposto a quantidade de contentores com frutos colhidos (x), a estimativa de frutos colhidos em kg (T) é expressa por uma função, onde a variável de decisão (VD) é:

X = quantidade de contentores com frutos colhidos em kg.

$$T(x) = 7,5x. \quad (1)$$

Temos uma função objetivo que representa a relação da VD de maneira proporcional a entrada de frutos em kg no *pack*. Tem-se uma média diária de 2.500 contentores sendo beneficiados, para ter a quantidade total de frutos colhidos em kg por dia, podemos apenas substituir os termos na função:

$$\begin{aligned} T(x) &= 7,5 \cdot 2500, \\ T(x) &= 18750 \text{ kg}. \end{aligned} \quad (2)$$

A meta diária necessária de produção é de 13 toneladas/dia, ou 13000 kg/dia, para o fechamento de um contêiner para exportação. Nesse primeiro sistema, esse valor é considerado uma primeira restrição de demanda. A capacidade de beneficiar frutos está diretamente relacionada à capacidade de expedir esses frutos. A seguinte restrição é representada assim:

$$\text{Restrição de demanda: } T(x) = 7,5x \leq 13000 \frac{\text{kg}}{\text{dia}} \quad (3)$$

A restrição ainda não considera a meta de refugo diário de 6%. Para descrever melhor essa relação, podemos construir a função da seguinte maneira:

$$T(x) = 7,5x + 0,06x_t, \quad (4)$$

onde, x_t representa $7,5x$ e substituídos os termos teremos uma meta de produção diária que considera as perdas de produção no cenário com 2500 contentores beneficiados de:

$$\begin{aligned} T(x) &= 7,5 + 0,06x_t, \\ T(x) &= 18750 + 0,06 \cdot 18750, \\ T(x) &= 18750 + 1125, \\ T(x) &= 19875 \text{ kg}. \end{aligned} \quad (5)$$

Também podemos considerar uma restrição de não-negatividade desse sistema:

$$T(x) = 7,5x \geq 0 \quad (6)$$

No cenário atual de produção da indústria, a produção diária estimada pelo controle interno é de aproximadamente 20.000 kg de frutas, o que excede a restrição de demanda diária estimada de 13.000 kg/dia e a produção diária considerando o refugo de 19875 kg. Para cálculo de demanda excedente (DE), podem ser usado:

$$\begin{aligned} DE &= 7,5 + 0,06x_t - 13000 \text{ kg}, \\ DE &= 19875 - 13000, \\ DE &= 6875 \text{ kg}. \end{aligned} \quad (7)$$

Para reduzir perdas, a indústria direciona a produção DE para o mercado interno (MI). A meta atual é direcionar 70% da produção diária para exportação e 30% para MI e refugo. No sistema operacionalizado na PO, a indústria não consegue atingir as metas propostas, pois sua capacidade de expedição de 13000 kg/dia representa apenas 65,40% do cenário otimizado de produção de 19875 kg/dia e 34,59% para MI e refugo.

Duas importantes considerações devem ser feitas sobre esse cenário produtivo. A primeira é que, se grande parte da fruta colhida atender mais a critérios de mercado interno, isso impactará na programação do contêiner do dia para exportação. Neste caso, a meta diária fica engessada em um planejamento semanal de logística e a demora em conseguir fechar um contêiner com as frutas de qualidade exigidas para exportação, gera o risco da expedição perder seu prazo de viagem. Isso significa mais tempo em refrigeração para as frutas perecíveis, que têm vida útil curta devido ao amadurecimento, mesmo com controle de temperatura. Em casos extremos, pode até mesmo levar à perda da venda.

Em segundo lugar, os valores calculados de produção são apenas estimativas. No momento do beneficiamento, o controle e a programação do embalagem de frutas são realizados de forma intuitiva e manual. Portanto, a produção estimada pode variar significativamente durante o processo de produção.

O controle em tempo real da quantidade de contentores com frutos colhidos em kg na usina, juntamente com a estimativa da DE e a meta de exportação na linha de produção, pode ajudar a corrigir problemas da colheita de forma mais rápida e eficaz. Se a quantidade de frutos colhidos estiver acima da meta de DE, a usina pode tomar medidas para orientar a colheita ou identificar problemas em tempo de produção na colheita antes que eles se tornem graves, como uma praga ou doença.

3 METODOLOGIA

Após validação de um possível problema de estimação, é importante gerar um processo de intervenção com impacto na produção. Para isso, foi realizada a modelagem de um produto mínimo viável (MVP) e definidas as seguintes métricas-chaves: taxa de precisão de contagem de contentores (TP); tempo médio de processamento por unidade de contentor (TM); demanda excedente (DE); percentual de exportação (PE) e nível de satisfação de usuários.

As imagens foram extraídas por meio do *Pygoogle_image*, um pacote *Python* que permite baixar imagens do Google Imagens [24]. O pacote é gratuito e de código aberto, e está disponível no PyPI. A seguinte *Keywords* de parâmetro foi utilizada: "caixa plástica vazada". Foram extraídas 800 imagens e após o pré-processamento

resultaram em 495 imagens prontas para o processo de rotulação.

As imagens do conjunto de dados foram devidamente anotadas, identificando as regiões que contêm os contentores de frutos. A rotulação do banco de dados foi realizada de forma sistemática com a utilização da ferramenta *LabelImg* [25], um *software* livre e de código aberto. As anotações foram salvas como arquivos XML no formato PASCAL VOC, usado pela *ImageNet* e suporta os formatos *YOLO*.

O *YOLOv8* foi selecionado para identificação do contentor por sua eficiência e eficácia comprovadas em tarefas de detecção de objetos em tempo real, especialmente em cenários com múltiplos objetos em uma única imagem. A rede *YOLOv8* foi implementada no ambiente em nuvem da Google Colaborary. O banco de dados rotulado foi carregado para um repositório no *Google Drive*.

Para implementar a rede, é necessário instalar a biblioteca *Collection Ultralytics* e outras bibliotecas, como *shutil* e *random*. Após a implementação das ferramentas essenciais, foi construída uma função para separar o conjunto de dados em dois tipos: treinamento e teste. O banco de dados final é composto por 495 imagens rotuladas com um único rótulo, 'contentor'. As imagens foram divididas em 396 para treino (80%) e 99 para teste (20%).

O modelo *YOLOv8l* foi utilizado para o treinamento, em modo de detecção. Hiperparâmetros foram configurados buscando o melhor desempenho. O modelo foi parametrizado para 300 ciclos, mas o treinamento foi interrompido precocemente porque nenhuma melhoria foi observada nas últimas 25 épocas. Esse procedimento de *EarlyStopping* foi parametrizado nas configurações de treino do modelo.

Figura 3 – Amostra de imagem extraída.



Fonte: imagem extraída pelo *Pygoogle_image*.

Figura 4 – Exemplo do conjunto de validação.



Fonte: autoria própria.

4 RESULTADOS

Após 113 épocas, o modelo *YOLOv8* foi executado e o melhor resultado do modelo foi obtido na época 93 (Tabela 1).

Tabela 1 – Principais métricas do treino.


Época	metrics/ precision	metrics/r ecall	metrics/mAP50
93	0.992	0.994	0.866

Fonte: autoria própria.

O desempenho do modelo no conjunto de validação foi ligeiramente superior ao desempenho no conjunto de treinamento. Isso indica que o modelo está aprendendo a identificar os contentores com maior precisão. Esse resultado é importante, pois o conjunto de validação é diferente dos outros conjuntos de dados, pois contém imagens de contentores retirados da linha de produção. Essas imagens representam objetos que o modelo não viu durante o treinamento.

A Figura 5 mostra a matriz de confusão do processo de classificação, indicando que o modelo se generaliza bem para objetos que não viu durante o treinamento. Isso demonstra que o modelo é capaz de aprender a identificar objetos de forma robusta. Os resultados indicam que o modelo é um bom candidato para a tarefa de detecção de objetos do tipo contentor. O modelo melhora seu desempenho com o treinamento e se generaliza bem para objetos que não viu durante o treinamento.

Figura 5 – Matriz de confusão do processo de classificação.



Fonte: autoria própria.

A matriz mostra que 126 objetos reais da classe contentor foram corretamente classificados e que o modelo teve um desempenho geral bom, com um *recall* de 92,2% e uma precisão de 91,3%. O *recall* indica a porcentagem de objetos reais que o modelo foi capaz de detectar corretamente. A precisão indica a porcentagem de objetos detectados que realmente são objetos reais. A Figura 6 mostra um contentor detectado em um vídeo na linha de empacotamento.

Figura 6 – Detecção em vídeo.



Fonte: autoria própria.

4 DISCUSSÕES E CONCLUSÕES

Foram explorados cenários de problemas de uma indústria agrícola e identificada que o controle de estimativas de produção em tempo de beneficiamento pode ser um importante indicador para otimizar a produção, mas a ausência de uma metodologia automatizada de mensuração e controle de contentores durante sua entrada no processo de beneficiamento de frutas é um importante gargalo para a mensuração e controle dessa produção em tempo real.

Foi proposta uma solução baseada em VC capaz auxiliar no controle em tempo real da quantidade de contentores com frutos colhidos em kg na usina e permitir o acompanhamento das seguintes métricas em tempo de produção: taxa de precisão de contagem de contentores (TP); tempo médio de processamento por unidade de contentor (TM); demanda excedente (DE) e percentual de exportação (PE). Métricas como a DE darão suporte a decisão na linha de produção para corrigir problemas de colheita de forma mais rápida e eficaz. Se a quantidade de frutos colhidos estiver acima da meta de DE, a usina pode tomar medidas para orientar a colheita dos frutos ou identificar problemas na colheita antes que eles se tornem graves, como uma praga ou doença.

A VC foi escolhida tanto por ser uma ótima abordagem de inspeção como pelo seu potencial para futuros avanços em sistemas de imagem combinadas a multicâmeras, o que pode permitir o escalonamento de soluções mais lineares, como a detecção de contentores, para abordagens mais complexas e robustas, como a detecção de detalhes de qualidade de frutos e o controle da produção em simultâneo. Em particular, a YOLOv8I se mostrou menos complexa em implementação que modelos anteriores e isso torna essa tecnologia mais acessível.

Com base nos resultados obtidos, pode-se concluir que a rede YOLOv8I é uma ferramenta eficaz para a identificação de contentores de frutos. A rede é capaz de atingir alta precisão, tanto em imagens quanto em vídeos, mesmo em condições adversas.

Para pesquisas futuras a rede YOLOv8 pode ser testada em versões mais aprimoradas, como a YOLOv8x, assim como aplicada a um conjunto de dados maior e mais diversificado, pois isso ajudaria a melhorar a generalização da rede para diferentes tipos de contentores e condições de iluminação. Experimentar o uso de segmentação na rede e

comparar os resultados atuais seria um importante incremento a esses resultados, porque é bastante desafiador diferenciar o conteúdo de formas geométricas semelhantes. A pesquisa operacional (PO) se mostrou uma importante ferramenta para delinear os problemas e identificar métricas essenciais de negócio para acompanhamento. Para pesquisas futuras, a PO pode ser mais aprimorada e trabalhada não apenas com uma variável de decisão e assim trazer novos conhecimentos desses processos de produção em usinas de beneficiamento de frutos.

Esse trabalho se limitou a explorar alguns dos desafios envolvidos no desenvolvimento de um sistema automatizado para identificação de contentores de frutos por meio de imagens e vídeos, como o entendimento de problema relevante de negócio, a montagem de um banco de imagens rotuladas e o treinamento de uma rede *YOLOv8l*. Em pesquisas futuras podem ser explorados outros desafios dessa solução, como a integração a *hardware* e sistemas existentes, assim como a visualização das métricas em ambiente de produção.

REFERÊNCIAS

- [1] Narendra, V., Hareesha, K. Quality Inspection and Grading of Agricultural and Food Products by Computer Vision- A Review. **International Journal of Computer Applications**, 2, 43-65, 2010. <https://doi.org/10.5120/612-863>. Disponível em: <https://www.ijcaonline.org/archives/volume2/number1/612-863>. Acesso em: 15 de dez. de 2023 às 09hs08min.
- [2] Brosnan, T., Sun, D. Improving quality inspection of food products by computer vision: a review. **Journal of Food Engineering**, 61, 3-16, 2004. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0260877403001833>. Acesso em: 15 de dez. de 2023 às 09hs10min.
- [3] Sun, D. Computer vision technology for food quality evaluation, **Academic Press**, dezembro 17, 2007. [Doi.org/10.1016/b978-0-12-373642-0.x5001-7](https://doi.org/10.1016/b978-0-12-373642-0.x5001-7).
- [4] Brosnan, T., Sun, D. Inspection and grading of agricultural and food products by computer vision systems—a review. **Computers and Electronics in Agriculture**, 36, 193-213, 2002. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169902001011>. Acesso em: 15 de dez. de 2023 às 09hs10min.
- [5] Saldaña, E., Siche, R., Luján, M., Quevedo, R. Review: computer vision applied to the inspection and quality control of fruits and vegetables. **Brazilian Journal of Food Technology**, 16, 254-272, 2013. Disponível em: <https://www.scielo.br/j/bjft/a/y5bZb5gBbdYS4SKrkGyZ7qr/?lang=em>. Acesso em: 15 de dez. de 2023 às 09hs13min.
- [6] Chopde, S., Patil, M., Shaikh, A., Chavhan, B., & Deshmukh, M. Developments in computer vision system, focusing on its applications in quality inspection of fruits and vegetables-A review. **Agricultural Reviews**, 38, 94-102, 2017. Disponível em: <https://arccjournals.com/journal/agricultural-reviews/R-1668>. Acesso em: 15 de dez. de 2023 às 09hs20min.
- [7] Shirsath, S.M; Telang, S. Fruit Quality Inspection using Image Processing. **International Journal of Advance Research and Innovative Ideas in Education**, 3, 1355-1359, 2017. Disponível em: http://ijariie.com/AdminUploadPdf/Fruit_Quality_Inspection_using_Image_Processing_ijariie6800.pdf. Acesso em: 15 de dez. de 2023 às 09hs25min.
- [8] Blasco, J., Munera, S., Aleixos, N., Cubero, S., & Moltó, E. Machine Vision-Based Measurement Systems for Fruit and Vegetable Quality Control in Postharvest.. **Advances in biochemical engineering/biotechnology**, 161, 71-91, 2017. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/28289768/>. Acesso em: 15 de dez. de 2023 às 09hs30min.
- [9] Li, J., Huang, W., Zhao, C. Machine vision technology for detecting the external defects of fruits — a review. **The Imaging Science Journal**, 63, 241 – 251, 2015. [Doi.org/10.1179/1743131X14Y.0000000088](https://doi.org/10.1179/1743131X14Y.0000000088).
- [10] Cubero, S., Lee, W., Aleixos, N., Albert, F., & Blasco, J. Automated Systems Based on Machine Vision for Inspecting Citrus Fruits from the Field to Postharvest—a Review. **Food and Bioprocess Technology**, 9, 1623-1639, 2016. Disponível em: <https://link.springer.com/article/10.1007/s11947-016-1767-1>. Acesso em: 15 de dez. de 2023 às 09hs36min.
- [11] Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Jitao, W., & Liu, C. (2014). Principles, developments and applications of computer vision for external quality inspection of fruits

- and vegetables: A review. **Food Research International**, 62, 326-343. Doi.org/10.1016/J.FOODRES.2014.03.012.
- [12] Sá, P. C. A.; Prates, R. M. Ciência de Dados na Indústria Vitivinícola: compreensão, pesquisa e maturação tecnológica. **XVI Brazilian Conference on Computational Intelligence** (CBIC 2023), Salvador, out. 8 a 11. Disponível em: https://sbic.org.br/wp-content/uploads/2023/10/ST05/CBIC_2023_paper174.pdf. Acesso em: 15 de dez. de 2023 às 09hs37min.
- [13] Santos, T., Souza, L., Santos, A., & Avila, S. Grape detection, segmentation and tracking using deep neural networks and three-dimensional association. **ArXiv**, abs/1907.11819, 2019. Disponível em: <https://arxiv.org/abs/1907.11819>. Acesso em: 15 de dez. de 2023 às 09hs45min.
- [14] Zhang, C., Ding, H., Shi, Q., Wang, Y. Grape Cluster Real-Time Detection in Complex Natural Scenes Based on YOLOv5s Deep Learning Network. **Agriculture**, vol. 12, p. 1242, 2022. Disponível em: <https://www.mdpi.com/2077-0472/12/8/1242>. Acesso em: 15 de dez. de 2023 às 09hs46min
- [15] Jocher, G., Chaurasia, A., & Qiu, J. (2023). YOLO by Ultralytics (Version 8.0.0) [ComputerSoftware]. Disponível em: <https://github.com/ultralytics/ultralytics>. Acesso em: 15 de dez. de 2023 às 09hs48min
- [16] Sá, P. C. A.; Prates, R. M. Ciência de Dados na Indústria Vitivinícola: compreensão, pesquisa e maturação tecnológica. **XVI Brazilian Conference on Computational Intelligence** (CBIC 2023), Salvador, out. 8 a 11. Disponível em: https://sbic.org.br/wp-content/uploads/2023/10/ST05/CBIC_2023_paper174.pdf. Acesso em: 15 de dez. de 2023 às 09hs37min.
- [17] BARROS, J.C. da S.M. de; FERRI, C.P.; OKAWA, H. Qualidade da uva fina de mesa comercializada na Ceasa de Campinas, 1993 - 1994. **Informações Econômicas**, São Paulo, v.25, n.7, p. 53 - 61, 1995.
- [18] BLEINROTH, E.W. Determinação do ponto de colheita. In: GORGATTI NETO, A.; GAYET, J.P.; BLEINROTH, E.W. et al. Uva para exportação: procedimentos de colheita e pós-colheita. Brasília: **EMBRAPA - SPI/FRUPEX**, 1993. p.20 -21. (Publicações Técnicas, 2).
- [19] BOLIANI, A.C. Avaliação fenológica de videiras *Vitis vinifera* L. cvs. Itália e Rubi na região oeste do estado de São Paulo 1994. 188f. **Tese Doutorado**- Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 1994.
- [20] M. F. Neves, A. W. Gray, et al., "Ferramentas para o futuro do agro: estratégias para posicionar o Brasil como fornecedor mundial sustentável de alimentos, bioenergia e outros agroprodutos," São Paulo: **Editora Gente**, 2021, pp. 1-320.
- [21] SEBRAE/MG. "Startups do Agronegócio: método de criação, planejamento e gestão de startups do agronegócio". Belo Horizonte: **SEBRAE/MG**, 2020, 168p. Disponível em: <https://doutoragro.com/wp-content/uploads/2021/06/Planejando-Start-Ups-Sebrae-Markestrat-compactado.pdf>. Acesso em: 15 de dez. de 2023 às 09hs54min
- [22] S. N. Luz, "Caracterização de packing houses de uvas na região de Petrolina/Juazeiro e proposição de uma lista de verificação para o desenvolvimento de projetos", Dissertação de Mestrado, Universidade Federal do Vale do São Francisco, Juazeiro, BA, 2016. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/39134>. Acesso em: 15 de dez. de 2023 às 09hs55min
- [23] F. A. Ferreira, T. S. Soares and A. C. G. C. Silva, "Análise da capacidade produtiva através do estudo de tempos e da simulação computacional: estudo de caso em um packing house na cidade de Petrolina-PE," in Anais do XXXVIII Encontro Nacional de Engenharia de Produção, Maceió, Alagoas, Brasil, 16-19 out. 2018, pp. 1-15.
- [24] Pinangé, A. (2021). Pygoogle_image. Disponível em: <https://pypi.org/project/pygoogle-image/>. Acesso em: 15 de dez. de 2023 às 09hs58min.
- [25] Lin, T. (2017). labelImg. Disponível em: <https://pypi.org/project/labelImg/1>. Acesso em: 15 de dez. de 2023 às 09hs59min