

Implementação de Deep Learning para Contagem e Segmentação de Ovos em Tempo Real

Bruno Raphael Facundo

Universidade Tecnológica Federal do
Paraná (UTFPR)

Medianeira-PR, Brasil

brunoraphaelfacundo@alunos.utfpr.edu.br

Pedro Luiz de Paula Filho

Universidade Tecnológica Federal
do Paraná (UTFPR)

Medianeira-PR, Brasil

pedrol@utfpr.edu.br

Juliano Rodrigo Lamb

Universidade Tecnológica Federal
do Paraná (UTFPR)

Medianeira-PR, Brasil

lamb@utfpr.edu.br

Abstract—Manual counting of eggs on production conveyors is a process prone to errors and inefficiencies, which can negatively impact productivity and the quality of the final product. Therefore, it is essential to implement solutions that automate this process, increasing the efficiency and accuracy of this task. This paper presents the development of a deep learning model using Python and YOLOv8 for real-time egg counting and segmentation. The model was trained on a dataset of 1,643 images created and annotated with Roboflow, which facilitated the preparation of images for training, testing, and validation. The results demonstrate that the proposed approach achieves high accuracy in egg detection and segmentation, highlighting its potential for implementation in automated systems in the poultry industry.

Keywords—deep learning, egg counting, image segmentation.

Resumo—A contagem manual de ovos em esteiras de produção é um processo suscetível a erros e ineficiências, o que pode impactar negativamente a produtividade e a qualidade do produto final. Por isso, é essencial a implantação de soluções que automatizem esse processo, aumentando a eficiência e a precisão dessa tarefa. Este trabalho apresenta o desenvolvimento de um modelo de deep learning utilizando Python e o YOLOv8 para contagem e segmentação de ovos em tempo real. O modelo foi treinado em um conjunto de dados de 1.643 imagens criado e anotado com o Roboflow, que facilitou a preparação das imagens para treinamento, teste e validação. Os resultados demonstram que a abordagem proposta alcança alta precisão na detecção e segmentação de ovos, evidenciando seu potencial para implementação em sistemas automatizados na indústria avícola.

Palavras-chave—deep learning, contagem de ovos, segmentação de imagens.

I. INTRODUÇÃO

A produção de ovos é essencial para a indústria agropecuária e para a segurança alimentar global, pois fornece uma fonte importante de proteínas e nutrientes essenciais para a alimentação humana, além de ser vital para a cadeia produtiva da avicultura, como na incubação de pintinhos [1].

Historicamente, na indústria avícola, a contagem de ovos tem sido realizada de forma manual, desta forma, os trabalhadores são responsáveis por contabilizar os ovos à medida que estes são transportados por uma esteira. Esse procedimento, além

de ser demorado, demanda uma precisão elevada e enfrenta diversos desafios operacionais [2]. A contagem manual também está suscetível a erros humanos, o que pode comprometer a eficiência do processo e, em situações onde as contagens imprecisas não são rapidamente identificadas e corrigidas, pode levar a um manejo inadequado da produção. Isso, por sua vez, pode impactar a qualidade final dos ovos produzidos e elevar os custos operacionais, reduzindo a lucratividade. Uma abordagem potencial para superar essas limitações é a automação do processo, utilizando câmeras que capturam imagens e processam os dados em tempo real para identificar e contar os ovos.

A detecção e segmentação de objetos por meio de redes neurais tem revolucionado a área de visão computacional, permitindo que sistemas automatizados identifiquem e classifiquem objetos em imagens e vídeos com alta precisão. Essa técnica envolve o treinamento de redes neurais convolucionais (CNNs) em grandes volumes de dados, para que possam aprender a reconhecer padrões complexos e características distintas dos objetos em diferentes contextos e ambientes [3].

O *deep learning*, um subcampo do aprendizado de máquina, tem sido amplamente utilizado em problemas de visão computacional, como a detecção e segmentação de objetos em imagens e vídeos. O modelo YOLO (*You Only Look Once*), em suas várias versões, é conhecido por sua capacidade de realizar detecções rápidas e precisas em tempo real, tornando-o uma escolha popular para aplicações industriais em que a rapidez é indispensável [4]. Ao mesmo tempo, o uso de plataformas como o Roboflow¹ para a anotação e o tratamento de imagens permite a criação de bases de dados robustas, essenciais para o treinamento eficaz desses modelos.

Existem diversas soluções comerciais no mercado, como Ovotron², EggXact³ e Munters⁴, que visam automatizar esse

¹<https://roboflow.com/>

²<https://www.ovotron.com.br/producos/>

³<https://www.hotraco-agri.com/en/poultry-solutions/eggxact-egg-counter/>

⁴<https://www.munters.com/en/solutions/farm-management/poultry-chicken-layer-hens/>

processo, utilizando câmeras e sistemas de visão computacional para identificar e contar os ovos, além de realizar outras tarefas referentes à análise de peso e área, como no trabalho de [5]. No entanto, essas soluções muitas vezes apresentam limitações significativas, especialmente para pequenos e médios produtores, como alto custo de implementação e manutenção, complexidade na integração com sistemas existentes e falta de flexibilidade para se adaptar a diferentes ambientes de produção [5]. Essas limitações justificam a necessidade de desenvolver novas soluções que sejam mais acessíveis e adaptáveis às necessidades específicas da indústria avícola.

Pesquisas recentes têm explorado abordagens de código aberto para automatizar a contagem de ovos com maior acessibilidade. No trabalho de [6] é apresentada uma solução que visa aumentar a eficiência de indústrias avícolas, utilizando o modelo YOLOv5 para detecção e contagem automatizada de ovos. Segundo o autor, o modelo treinado obteve ótima precisão na detecção de ovos, atingindo um *mean Average Precision* (mAP) de 90% durante o treinamento.

Outro trabalho relevante é o de [7], que propõe uma solução utilizando o algoritmo YOLOv5-DSE. O objetivo dos autores é superar limitações dos métodos tradicionais de contagem, como a baixa precisão, especialmente em cenários com ovos sobrepostos, mudanças de posição e grandes variações de tamanho. Foram implementados três módulos principais: um detector de ovos baseado no modelo YOLOv5, um módulo de rastreamento DeepSORT que mantém a localização de cada ovo entre os *frames*, e um módulo de codificação espacial (SE) que calcula a contagem precisa de ovos. Para treinamento do módulo de detecção, foram utilizadas 1400 imagens, e 600 imagens para teste. O sistema alcançou um mAP de 99,52%, superando métodos anteriores de contagem baseados em YOLO e outros modelos.

Contudo, mesmo que as soluções apresentadas sejam promissoras na contagem de ovos, não incorporam métodos de segmentação e, com isso, é limitada uma análise mais detalhada dos ovos detectados, necessária para avaliar sua conformidade com os padrões de qualidade, exigidas pelo mercado de produtos avícolas.

A avaliação da qualidade e padronização dos ovos colhidos nas esteiras é uma tarefa importante, e não pode ser feita unicamente por meio de sua detecção pela rede neural a ser empregada. Para isso, é viável a aplicação da segmentação, que engloba a subdivisão de regiões ou objetos com características específicas em uma imagem digital [8]. Esta técnica desempenha um papel primordial e extremamente importante no escopo abordado, pois permite a extração de informações essenciais para análises posteriores [9]. No escopo em questão, informações como a área ocupada por um ovo na esteira, poderiam ser utilizadas como parâmetro para determinar seu

tamanho aproximado e, conseqüentemente, avaliar a saúde e a produtividade das aves responsáveis pela produção. Além disso, essas informações podem facilitar a seleção mais precisa dos ovos a serem encaminhados para os consumidores. Dentre outros tratamentos, caso a produção apresente variações, pode-se ajustar a alimentação das aves, modificando a ração, ou intervindo com medicamentos em caso de detecção de doenças. Se houver sinais de sujidade, é necessário identificar a causa e realizar os devidos ajustes para garantir a qualidade dos ovos.

Com base nessas lacunas, o presente trabalho propõe o desenvolvimento de um sistema que integre contagem e segmentação de ovos em tempo real, utilizando o modelo YOLOv8. O objetivo é oferecer uma solução automatizada para a indústria avícola, como alternativa à contagem manual, que seja mais acessível e flexível em comparação às soluções comerciais existentes. Embora os testes em ambientes de produção tenham apresentado resultados promissores, podem ser feitos aprimoramentos adicionais para garantir sua aplicabilidade em larga escala e em diferentes cenários de produção.

II. MATERIAIS E MÉTODOS

O fluxograma de atividades seguido para o desenvolvimento da ferramenta responsável pela contagem e segmentação de ovos em esteira de produção pode ser observado na Figura 1. O método é constituído por seis etapas, sendo elas: seleção do modelo de aprendizado profundo; criação do *dataset* para treinamento e testes; treinamento do modelo para detecção e segmentação; desenvolvimento da ferramenta de contagem de ovos; teste e pós-processamento das detecções; e análise dos resultados.

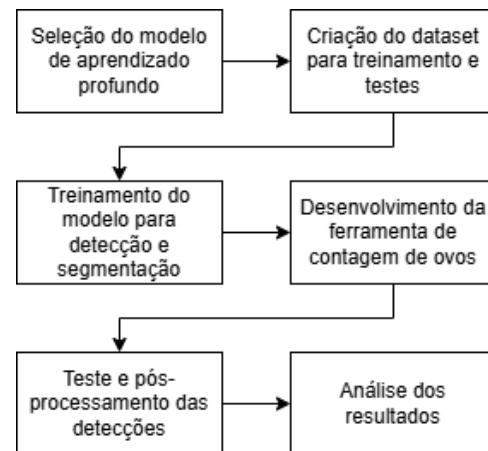


Fig. 1. Autoria Própria - Fluxograma de atividades

A primeira etapa consistiu em selecionar um modelo de aprendizado profundo capaz de realizar as tarefas de detecção e

segmentação dos ovos em tempo real. Para isso, foi selecionado o modelo YOLOv8s-seg, implementado através da biblioteca Ultralytics. Essa é uma versão otimizada do YOLOv8, focada não apenas na detecção, mas também na segmentação de instâncias, sendo particularmente eficaz para a contagem e segmentação de ovos devido à sua precisão elevada e capacidade de processar imagens em tempo real [10].

Os modelos YOLO são conhecidos por realizar detecção de objetos em uma única etapa, o que os tornam muito rápidos [11]. Em tarefas como a contagem e segmentação de ovos, essa rapidez é essencial para garantir que o sistema possa acompanhar a velocidade da produção sem perder dados.

É importante ressaltar que o modelo YOLOv8 exige uma licença para uso comercial. No entanto, existem algumas características técnicas que justificam sua escolha. Diferentemente de outras versões, o YOLOv8-seg é a única que integra a detecção e segmentação de instâncias em uma única etapa, mantendo alta precisão e a eficiência necessária para operar em ambientes industriais com alta demanda, como em linhas de produção de ovos. Além disso, o suporte e atualizações constantes, favorecem a manutenção e escalabilidade do produto a longo prazo.

A segunda etapa consistiu na criação da base de dados utilizada para o treinamento do modelo, composta por 1.643 imagens, semelhantes à Figura 2, capturadas em campo, diretamente em uma indústria avícola. As imagens são *frames* retirados de três vídeos, cada um com uma hora de duração, gravados por uma câmera IP posicionada sobre a esteira de produção de ovos. Esses vídeos capturaram o fluxo contínuo de ovos na linha de produção, possibilitando uma grande variedade de cenários e condições para o treinamento do modelo, como variações de iluminação e posicionamento dos ovos.

Para assegurar uma anotação precisa, foram aplicadas máscaras de segmentação em cada imagem, permitindo a identificação e delimitação dos ovos, como ilustrado na Figura 3. As ferramentas da plataforma Roboflow foram utilizadas para gerar as anotações, posteriormente exportadas no formato padrão YOLO, garantindo compatibilidade direta com o modelo e facilitando o processo de treinamento. A escolha do formato YOLO para anotação também otimizou a importação dos dados para o *framework* Ultralytics, que gerenciou o treinamento e a avaliação do modelo.

As 1.643 imagens foram distribuídas da seguinte forma: 1.150 imagens (70%) para treinamento, 329 imagens (20%) para validação e 164 imagens (10%) para teste, assegurando um conjunto de dados equilibrado e representativo. O pré-processamento incluiu o redimensionamento das imagens de 1920x1080 para 640x640 pixels, a fim de balancear a qualidade visual com a eficiência computacional. Esse redimensionamento reduziu a demanda por recursos e tempo de processa-




Fig. 2. Autoria Própria - Exemplo de imagem utilizada para a criação do dataset para o treinamento do modelo de detecção e segmentação de ovos

mento, sem comprometer significativamente a precisão.



Fig. 3. Autoria Própria - Exemplo de imagem do conjunto de dados com as máscaras de segmentação

A terceira etapa, referente ao treinamento do modelo, foi realizada no ambiente Google Colab⁵, no qual os usuários podem escrever e executar código Python⁶ diretamente no navegador, sem a necessidade de configuração adicional. Uma de suas

⁵<https://colab.research.google.com/>

⁶<https://www.python.org/>

vantagens é o acesso gratuito a GPUs (*Graphics Processing Unit*), o que possibilita a execução de tarefas paralelas de maneira mais rápida, reduzindo significativamente o tempo de processamento.

Uma das formas de regularizar uma rede neural contra o *overfitting* é utilizar *weight decay* (decaimento dos pesos) [12]. Essa técnica possibilita que os parâmetros mantenham uma norma estável. Por isso, o otimizador AdamW, proposto por [13], foi utilizado no treinamento do modelo, sendo uma prática padrão no treinamento de modelos YOLO.

AdamW (*Adaptive Moment Estimation with Weight Decay*) é uma variante do otimizador Adam [14], amplamente utilizada em treinamentos de redes neurais profundas. Ele foi projetado para corrigir um problema com o Adam relacionado ao *weight decay*, tornando o treinamento mais estável e eficaz em diversas tarefas de aprendizado profundo.

Para o treinamento do modelo foram utilizados os parâmetros presentes na Tabela I.

TABELA I
PARÂMETROS AJUSTADOS PARA O TREINAMENTO DO MODELO
YOLOV8S-SEG

Parâmetro	Valor
Otimizador	AdamW
Learning rate	2×10^{-3}
Momentum	0,9
Weight decay	5×10^{-4}
Epochs	100
Image size	640

A quarta etapa, referente ao desenvolvimento da ferramenta de contagem de ovos, foi realizada no ambiente JupyterLab⁷, uma interface que, assim como o Google Colab, permite a criação de *notebooks* interativos, em que código e explicações textuais podem ser combinados, com o diferencial de permitir a criação de janelas de visualização de vídeos, por ser executado em ambiente local. Para isso, optou-se pela linguagem de programação Python, uma escolha que se fundamenta na ampla adoção da linguagem em projetos de visão computacional e aprendizado de máquina, além de possuir uma vasta gama de bibliotecas, como o OpenCV⁸, utilizada para a exibição dos resultados da segmentação e para a realização da contagem dos ovos nos vídeos, sendo essencial para manipulação de imagens e vídeos, permitindo operações como leitura, escrita e transformação de dados visuais, além de oferecer suporte para exibir as máscaras geradas pelo modelo de segmentação.

⁷<https://jupyter.org/>

⁸<https://opencv.org/>

A quinta etapa consistiu em avaliar a eficácia do modelo através de testes práticos em condições reais de operação. Para a realização da contagem e segmentação dos ovos nas imagens, uma visualização é gerada com o uso da biblioteca OpenCV para o vídeo em processamento, incluindo uma área de interesse delimitada, conforme ilustrado na Figura 4. Cada *frame* do vídeo é redimensionado para uma resolução de 1020x500 *pixels*, o que proporciona um equilíbrio entre a qualidade visual das imagens e a velocidade de processamento.




Fig. 4. Autoria Própria - Área de interesse para segmentação e contagem de ovos

A cada *frame* do vídeo, o modelo realiza a detecção dos ovos e gera suas respectivas máscaras de segmentação. Para assegurar que cada ovo seja contabilizado apenas uma vez ao atravessar a área de interesse, o código aplica uma função de rastreamento. Esse processo permite que o sistema determine o ponto central de cada ovo e atribua a ele um identificador exclusivo, facilitando o rastreamento e evitando duplicidades na contagem. Assim que um ovo entra na área de interesse, sua máscara é exibida e seu identificador é adicionado a uma lista, prevenindo contagens repetidas.

Além da contagem, o sistema calcula métricas como a área média ocupada pelos ovos, bem como o tamanho mínimo e máximo detectado. Dessa forma, é possível monitorar a consistência da produção em termos de dimensões dos ovos, ajudando a identificar e excluir objetos erroneamente classificados pelo modelo. Esse mecanismo de controle de erros será discutido de maneira mais aprofundada na seção de resultados, detalhando o impacto e as melhorias proporcionadas pela abordagem adotada.

A última etapa consiste na avaliação de resultados de detecção pelo modelo durante o treinamento. Para isso foram utilizadas as métricas de *Recall* e *Precisão*. Para avaliar a

segmentação, foram utilizadas as métricas mAP nos limiares de *Intersection over Union* (IoU) de 50% (mAP₅₀) e de 50% a 95% (mAP₅₀₋₉₅). Essas métricas são utilizadas para avaliar o desempenho em diferentes cenários de sobreposição entre as previsões do modelo e as anotações reais.

A Precisão (P) é definida como a razão entre o número de verdadeiros positivos (TP) e a soma de verdadeiros positivos e falsos positivos (FP), conforme a Equação 1, e indica a proporção de previsões corretas em relação ao total de previsões feitas pelo modelo. Um valor alto de precisão indica que o modelo faz poucas classificações incorretas [15].

$$P = \frac{TP}{TP + FP} \quad (1)$$

O *Recall* (R), por outro lado, é a razão entre o número de verdadeiros positivos e a soma de verdadeiros positivos e falsos negativos, conforme a Equação 2. Ele mede a capacidade do modelo de identificar todas as instâncias relevantes no conjunto de dados. Um *recall* alto indica que o modelo perdeu poucas instâncias relevantes [15].

$$R = \frac{TP}{TP + FN} \quad (2)$$

O IoU é utilizado para calcular a sobreposição entre duas áreas A e B. Ele é calculado dividindo-se a intersecção pela união entre as duas áreas, como mostra a Equação 3. Em casos de segmentação, o IoU é calculado entre as máscaras preditas e anotadas [16].

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad (3)$$

A mAP é a média das precisões em diferentes limiares de IoU, e é calculada a partir da precisão média (AP) para cada classe, utilizando a Equação 4. A AP é obtida pela integração da curva de precisão em função do *recall* em vários pontos de *recall* [15].

$$AP = \int_0^1 P(R) dR \quad (4)$$

O mAP₅₀ é a média das APs considerando apenas um limiar de IoU de 50%, que pode ser calculado utilizando a Equação 5, e o mAP₅₀₋₉₅ é a média das APs calculadas em vários limiares de IoU, de 50% a 95% em incrementos de 5%, como pode ser visto na Equação 6 [17].

$$\text{mAP}_{50} = \frac{1}{N} \sum_{i=1}^N AP_{50}(i) \quad (5)$$

$$\text{mAP}_{50-95} = \frac{1}{N} \sum_{i=1}^N \frac{1}{10} \sum_{t=50}^{95} AP_t(i) \quad (6)$$

Essas são métricas padrão ao avaliar o desempenho de treinamento de modelos YOLO e, com base nesses cálculos, é possível obter uma compreensão detalhada do desempenho do modelo, o que permite uma análise mais profunda dos resultados alcançados durante o treinamento e testes.

III. RESULTADOS E DISCUSSÃO

A avaliação do treinamento do modelo YOLOv8s-seg, realizado por meio das métricas estabelecidas, obteve resultados de desempenho altamente satisfatórios, conforme detalhado na Tabela I. As métricas foram calculadas para as tarefas de detecção e segmentação de ovos.

TABELA II
RESULTADO PARA AS MÉTRICAS DE DESEMPENHO DO TREINAMENTO DO MODELO YOLOv8s-SEG

	Precisão (P)	Recall (R)	mAP ₅₀	mAP ₅₀₋₉₅
Detecção	0,983	0,994	0,994	0,912
Segmentação	0,983	0,994	0,994	0,812

Os valores elevados de precisão e *recall* para ambas as tarefas (detecção e segmentação) indicam que o modelo conseguiu identificar e segmentar ovos de forma extremamente eficaz. A métrica mAP₅₀, que reflete a precisão média considerando um limiar de 50% de IoU, foi de 0,994 para ambas as tarefas, demonstrando que o modelo possui uma excelente capacidade de detectar e segmentar ovos mesmo em condições variadas de iluminação e posicionamento na esteira.

No entanto, a métrica mAP₅₀₋₉₅, que considera um intervalo mais amplo de IoU (50% a 95%), apresentou uma leve queda, especialmente para a segmentação (0,812). Isso pode indicar que, embora o modelo seja robusto na maioria dos casos, ele pode ter alguma dificuldade em cenários nos quais os ovos estão parcialmente ocluídos, como nos casos em que existem muitos ovos sobre a esteira em momentos de produção elevada, ou em posições desfavoráveis para a detecção e segmentação.

Para avaliar a performance do modelo em um ambiente de produção, foram utilizados vídeos da esteira de produção com diferentes resoluções. Durante esses testes, observou-se que em algumas situações, falhas na esteira eram erroneamente reconhecidas como ovos pelo modelo, especialmente em vídeos de resolução inferior, como acontece no caso da Figura 5, cuja resolução é de 640x640 *pixels*. Isso resultava em uma precisão de 99,06% na contagem total de ovos.

Para mitigar esse problema, foi implementada uma segunda verificação baseada na área ocupada pelos ovos identificados. Inicialmente, foi calculada a área média ocupada por cada ovo em várias imagens, e posteriormente, foram definidos os limites mínimo e máximo aceitáveis para essa área. Caso um objeto identificado não estivesse dentro dessa faixa aceitável, ele não




Fig. 5. Autoria Própria - Exemplo falha na esteira sendo reconhecida como ovo em vídeo com resolução 640x640

seria contabilizado como um ovo. Essa abordagem foi eficiente em eliminar falsos positivos, resultando em uma precisão de 100% na contagem.

O resultado final do sistema, exibindo a detecção, segmentação e contagem de ovos em tempo real, pode ser observado na Figura 6. Nela é possível observar o ponto central criado para o rastreamento e contagem dos ovos e a máscara de segmentação criada pelo modelo YOLOv8.




Fig. 6. Autoria Própria - Detecção, contagem e segmentação de ovos em tempo real

IV. CONCLUSÃO

Neste trabalho, foi utilizado o modelo YOLOv8s-seg para realizar a contagem e segmentação de ovos em uma esteira de produção, permitindo a construção de um sistema robusto que pode operar em tempo real, o que é essencial para aplicações industriais.

Os resultados obtidos foram altamente satisfatórios, com precisão e *recall* elevados tanto nas tarefas de detecção quanto de segmentação. Apesar dos ótimos resultados, o estudo também identificou desafios, como a ocorrência de falsos positivos devido a falhas na esteira. Para mitigar esse problema, foi implementada uma verificação adicional baseada na área dos objetos detectados, o que melhorou significativamente a precisão da contagem.

Como trabalhos futuros, sugere-se a exploração de técnicas mais avançadas de pós-processamento, como a criação de novas classes para classificação das falhas na esteira e de ovos contendo rachaduras e manchas, a fim de melhorar ainda mais a precisão do sistema. Além disso, a expansão do conjunto de dados com imagens capturadas em diferentes condições de iluminação e com diferentes tipos de ovos pode aumentar a generalização do modelo.

AGRADECIMENTOS

A Universidade Tecnológica Federal do Paraná (UTFPR) e aos orientadores pela orientação valiosa e apoio contínuo ao longo desta pesquisa.

REFERÊNCIAS

- [1] R. V. NUNES, P. C. POZZA, C. G. V. NUNES, E. CAMPESTRINI, R. KÜHL, L. D. ROCHA, and F. G. P. COSTA, "Valores energéticos de subprodutos de origem animal para aves," *Revista Brasileira de Zootecnia*, vol. 34, no. 4, p. 1217–1224, Jul 2005. [Online]. Available: <https://doi.org/10.1590/S1516-35982005000400017>
- [2] I. KANJANASURAT, W. KRUNGSEANMUANG, V. CHAOWALIT-TAWIN, and B. PURAHONG, "Egg-counting system using image processing and a website for monitoring," in *2021 7th International Conference on Engineering, Applied Sciences and Technology (ICEAST)*, 2021, pp. 101–104. [Online]. Available: <https://doi.org/10.1109/ICEAST52143.2021.9426295>
- [3] B. ROMÃO, "Redes neurais convolucionais para a detecção de objetos," Master's thesis, Pontifícia Universidade Católica de Campinas, Apr. 2023, dissertação de mestrado. [Online]. Available: <https://repositorio.sis.puc-campinas.edu.br/xmlui/handle/123456789/16933>
- [4] T. M. LEITE, "Deep learning em dois estágios para detecção e classificação de doenças em folhas de plantas com aplicação em dispositivos móveis," Dissertação de Mestrado, USP, Instituto de Ciências Matemáticas e de Computação, São Carlos, 2021. [Online]. Available: <https://doi.org/10.11606/D.55.2021.tde-02022022-121135>
- [5] J. ALIKHANOV, S. M. PENCHEV, T. D. GEORGIEVA, A. MOLDAZHANOV, A. KULMAKHAMBETOVA, Z. SHYNYBAY, E. STEFANOV, and P. I. DASKALOV, "Design and performance of an automatic egg sorting system based on computer vision," *TEM Journal*, vol. 8, no. 4, pp. 1319–1325, 2019. [Online]. Available: <https://doi.org/10.18421/TEM84-31>
- [6] A. VINOD, D. MOHANTY, A. JOHN, and B. DEPURU, "Application of artificial intelligence in poultry farming - advancing efficiency in poultry farming by automating the egg counting using computer vision system," 08 2023. [Online]. Available: <https://doi.org/10.21203/rs.3.rs-3266412/v1>
- [7] D. WU, D. CUI, M. ZHOU, Y. WANG, J. PAN, and Y. YING, "Using yolov5-dse for egg counting in conventional scale layer farms," *IEEE Transactions on Industrial Informatics*, pp. 1–10, 2024. [Online]. Available: <https://doi.org/10.1109/TII.2024.3452270>

- [8] R. C. GONZALEZ and R. E. WOODS, *Processamento Digital de Imagens*, 3rd ed. Editora Blucher, 2009. [Online]. Available: <https://books.google.com.br/books?id=9CbTDwAAQBAJ&lpg=PA1&ots=zinFRicVui&dq=Processamento%20Digital%20de%20Imagens%20gonzalez&lr&hl=pt-PT&pg=PA1#v=onepage&q&f=false>
- [9] M. F. S. SALDANHA and C. C. FREITAS, “Segmentação de imagens digitais: Uma revisão,” in *Anais do 9º Workshop dos Cursos de Computação Aplicada do INPE*. São José dos Campos: INPE, 2009. [Online]. Available: <http://urlib.net/ibi/8JMKD3MGP8W/37NC86S>
- [10] J. TERVEN, D. M. CORDOVA-ESPARZA, and J. A. ROMERO-GONZÁLEZ, “A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas,” *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, 2023. [Online]. Available: <https://doi.org/10.3390/make5040083>
- [11] E. FIGUEIREDO and E. SILVA, “Combate ao covid19: Detecção em tempo real de indivíduos sem máscara em ambiente escolar por meio de deep learning,” in *Anais do XV Brazilian e-Science Workshop*. Porto Alegre, RS, Brasil: SBC, 2021, pp. 113–120. [Online]. Available: <https://sol.sbc.org.br/index.php/bresci/article/view/15796>
- [12] I. GOODFELLOW, Y. BENGIO, and A. COURVILLE, *Deep Learning*. MIT Press, 2016. [Online]. Available: <http://www.deeplearningbook.org>
- [13] I. LOSHCHILOV and F. HUTTER, “Decoupled weight decay regularization,” 2019. [Online]. Available: <https://arxiv.org/abs/1711.05101>
- [14] D. P. KINGMA and J. BA, “Adam: A method for stochastic optimization,” 2017. [Online]. Available: <https://arxiv.org/abs/1412.6980>
- [15] S. WANG, X. CAO, M. WU, C. YI, Z. ZHANG, H. FEI, H. ZHENG, H. JIANG, Y. JIANG, X. ZHAO, X. ZHAO, and P. YANG, “Detection of pine wilt disease using drone remote sensing imagery and improved yolov8 algorithm: A case study in weihai, china,” *Forests*, vol. 14, no. 10, p. 2052, 2023. [Online]. Available: <https://doi.org/10.3390/f14102052>
- [16] S. MINAEE, Y. BOYKOV, F. PORIKLI, A. PLAZA, N. KEHTARNAVAZ, and D. TERZOPOULOS, “Image segmentation using deep learning: A survey,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 7, pp. 3523–3542, 2022. [Online]. Available: <https://doi.org/10.1109/TPAMI.2021.3059968>
- [17] H. HUANG, G. LAN, J. WEI, Z. ZHONG, Z. XU, D. LI, and F. ZOU, “Tli-yolov5: A lightweight object detection framework for transmission line inspection by unmanned aerial vehicle,” *Electronics*, vol. 12, no. 15, p. 3340, 2023. [Online]. Available: <https://doi.org/10.3390/electronics12153340>