



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:**
Limitações e possibilidades



UTILIZAÇÃO DE IA E REDE NEURAL PARA IDENTIFICAÇÃO DE MORANGOS

LUANA DOS SANTOS CORDEIRO – luana.cordeiro4@aluno.unip.com.br
UNIVERSIDADE PAULISTA - UNIP

MADALENA DE OLIVEIRA BARBOSA DIVINO - madalena.divino@aluno.unip.br
UNIVERSIDADE PAULISTA - UNIP

FERNANDA PEREIRA LEITE AGUIAR - fernanda.aguiar11@aluno.unip.br
UNIVERSIDADE PAULISTA - UNIP

SUELY DOS SANTOS SOUSA - suely.sousa3@aluno.unip.br
UNIVERSIDADE PAULISTA - UNIP

PROF. DR. MARCELO TSUGUIO OKANO - marcelo.okano1@docente.unip.br
UNIVERSIDADE PAULISTA - UNIP

ÁREA: 3. PESQUISA OPERACIONAL
SUBÁREA: 3.7 – INTELIGÊNCIA COMPUTACIONAL

RESUMO: ESTE ARTIGO INVESTIGA A APLICAÇÃO DE TÉCNICAS DE VISÃO COMPUTACIONAL NA IDENTIFICAÇÃO DE MORANGOS EM IMAGENS, COM FOCO NA UTILIZAÇÃO DO DEEP LEARNING (DL) OU APRENDIZADO PROFUNDO E DA REDE NEURAL CONVOLUCIONAL (CNN) YOU ONLY LOOK ONCE (YOLOV8). CONSIDERANDO A RELEVÂNCIA DO MORANGO NA CADEIA PRODUTIVA DE FRUTAS NO BRASIL E NO MUNDO, O DESENVOLVIMENTO DE TECNOLOGIAS INOVADORAS PARA IDENTIFICAÇÃO E DETECÇÃO É CRUCIAL PARA A AUTOMAÇÃO E MELHORIA DOS PROCESSOS DE SELEÇÃO. O ESTUDO APRESENTA UMA ANÁLISE DETALHADA DO PROCESSO DE TREINAMENTO DA REDE NEURAL CONVOLUCIONAL YOLOV8M, ESPECIFICAMENTE VOLTADA PARA A IDENTIFICAÇÃO DE MORANGOS EM IMAGENS. DURANTE O TREINAMENTO, FOI OBSERVADO UM PROGRESSO SIGNIFICATIVO NO DESEMPENHO DO MODELO, CONFORME INDICADO PELAS MÉTRICAS DE PRECISÃO DA CAIXA (BOXP), REVOCAÇÃO (R) E MAP50. ESTE TRABALHO NÃO APENAS CONTRIBUI PARA O AVANÇO DO CAMPO DA VISÃO COMPUTACIONAL, MAS TAMBÉM OFERECE INSIGHTS VALIOSOS SOBRE O TREINAMENTO DE REDES NEURAS CONVOLUCIONAIS PARA A IDENTIFICAÇÃO DE MORANGOS, PROMOVENDO POTENCIALMENTE MAIOR EFICIÊNCIA E PRECISÃO NA SELEÇÃO DE FRUTAS.

PALAVRAS-CHAVES: REDES NEURAS CONVOLUCIONAIS; VISÃO COMPUTACIONAL; APRENDIZAGEM PROFUNDA; YOLOV8M.

1. INTRODUÇÃO

O morango é um produto de grande relevância na cadeia produtiva de frutas do Brasil, e o desenvolvimento de novas tecnologias e técnicas para sua identificação e detecção pode contribuir significativamente para a automatização e melhoria da seleção dos melhores exemplares. De acordo com dados da Organização das Nações Unidas para Agricultura e Alimentação (FAO), o Brasil produziu cerca de 183.923 toneladas de morangos em 2022 (FAO, 2024). O sistema produtivo de frutas é uma das cadeias mais importantes do país, posicionando o Brasil em 3º lugar no ranking mundial de produção, com um volume anual de 45 milhões de toneladas. Esse número é expressivo, considerando as enormes quantidades desperdiçadas ao longo de toda a cadeia produtiva (EMBRAPA, 2023).

Os morangos, membros da família das rosáceas, passam por um ciclo de crescimento que inclui floração, frutificação e amadurecimento. Eles amadurecem rapidamente, em aproximadamente quatro semanas desde a floração até o fruto maduro, e são altamente valorizados nos mercados da América, Europa e Ásia. Sua produção vem crescendo nas últimas décadas devido à alta demanda dos consumidores e à sua variedade de aplicações (ZHOU et al., 2021; BONOW et al., 2023).

Essas frutas são amplamente apreciadas em todo o mundo, tanto pelo sabor quanto pelos benefícios nutricionais. No Brasil, os principais produtores de morango são os estados do Sudeste e Sul, mas novas técnicas de produção têm permitido o cultivo durante todo o ano e em outras regiões do país (PBMH & PIMO, 2019).

O desenvolvimento de novas tecnologias digitais trouxe grandes avanços na resolução de desafios complexos por meio do reconhecimento de padrões. A detecção automática de morangos pode ajudar a reduzir desperdícios ao longo de sua cadeia produtiva, uma vez que, devido ao rápido amadurecimento dos morangos, a identificação e classificação do estado de maturidade são referências valiosas para monitorar a produção. Este artigo, inicialmente, foca na identificação de morangos.

A Inteligência Artificial tem sido amplamente utilizada em diversas áreas, inclusive na agricultura. Nos últimos anos, técnicas de aprendizado de máquina e aprendizado profundo como detecção e classificação de objetos por meio de imagens e vídeos, têm sido aplicadas em pesquisas sobre morangos (ZHOU et al., 2021).

Nesse contexto, a Visão Computacional e o aprendizado profundo emergem como ferramentas tecnológicas robustas. As Redes Neurais e o aprendizado profundo têm sido utilizados com sucesso em inúmeras aplicações, especialmente na detecção de frutas na

agricultura, oferecendo soluções para problemas complexos (SA et al., 2016). Assim, a identificação de morangos com técnicas de aprendizado de máquina e aprendizado profundo apresenta viabilidade significativa, especialmente nos setores agrícola e industrial, tornando-se crucial para a otimização de processos na agricultura, aumentando a eficiência e reduzindo desperdícios. No Brasil, aproximadamente 26 milhões de toneladas de alimentos são desperdiçados anualmente, dos quais 5,3 milhões de toneladas são frutas e 5,6 milhões de toneladas são hortaliças (CEDES, 2018).

Este estudo apresenta o uso de técnicas de Visão Computacional para análise de imagens e identificação de morangos, utilizando a aplicação de *Deep Learning* (DL) ou aprendizado profundo e a Rede Neural Convolucional *You Only Look Once* (YOLOv8), reconhecida por sua eficiência na detecção de objetos. Além disso, avaliar o impacto dessas tecnologias em setores como a agricultura, destacando suas vantagens, possíveis limitações e sugestões para trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo apresenta-se as tecnologias e conceitos utilizados nesta pesquisa. Segundo Wang et al. (2024), a detecção de frutas por meio de tecnologias de processamento de imagens passou por três fases de evolução: processamento de imagens digitais convencionais, processamento de imagens com base em aprendizado de máquina e processamento de imagens com base em aprendizado profundo. No primeiro estágio, técnicas como análise de limiar, detecção de bordas, crescimento de região e matriz de co-ocorrência de nível de cinza são usadas para extrair características como cor, tamanho, forma e textura a fim de identificar frutas.


Em comparação com os métodos tradicionais, os algoritmos de detecção baseados em aprendizado profundo demonstram vantagens como melhor adaptabilidade, alta velocidade de detecção e elevada taxa de precisão. A integração da Visão Computacional com a tecnologia de Inteligência Artificial tem sido incorporada aos processos de produção agrícola, substituindo atividades intensivas em mão de obra e melhorando fatores de produtividade (WANG et al., 2022).

Backes e Júnior (2019) enfatizam que um sistema de Visão Computacional consiste em vários estágios: **Aquisição:** responsável pela obtenção de imagens, simulando a função ocular. **Processamento de Imagem:** visa melhorar as características da imagem, podendo personalizá-la ou preparar para as etapas seguintes. **Segmentação:** divide a imagem em áreas de interesse. **Extração de Características/Análise de Imagens:** obtém um conjunto de características do

objeto de interesse, permitindo sua identificação. **Reconhecimento de Padrões:** classifica ou agrupa imagens com base em suas características.

A Figura 1 ilustra o esquema do funcionamento de um sistema de visão computacional.

FIGURA 1 - Esquema de um sistema de visão computacional



Fonte: Adaptado de BACKES e JUNIOR (2019)

Com o avanço das aplicações da Inteligência Artificial, técnicas como o aprendizado profundo, estão sendo amplamente utilizadas em cenários agrícolas, um campo conhecido como agricultura inteligente. Essa abordagem incorpora uma variedade de tecnologias digitais, incluindo aprendizado profundo, *Big Data* e Internet das Coisas (IoT), aplicadas à agricultura (LIU et al., 2021). Conforme Ludermir (2021), o aprendizado de máquina tem como objetivo melhorar o desempenho dos programas através de modelos, sendo necessário muitos exemplos para gerar conhecimento computacional, representado por hipóteses derivadas dos dados. A inferência indutiva é o principal método para derivar novos conhecimentos e prever eventos futuros em aprendizado de máquina, onde a correta generalização depende da qualidade dos dados. Existem três tipos principais de aprendizado de máquina: supervisionado, não supervisionado e de reforço.

No tipo supervisionado, o algoritmo necessita de exemplos rotulados para criar um classificador que determine corretamente a classe dos novos exemplos. No caso do não supervisionado, os exemplos são agrupados com base em suas semelhanças. Já no reforço, o algoritmo recebe sinais de reforço para avaliar suas hipóteses. Uma aplicação eficaz do aprendizado de máquina requer um bom conjunto de exemplos, técnicas para melhorar a qualidade dos dados, seleção adequada de algoritmos, definição de parâmetros e monitoramento contínuo do sistema para garantir seu desempenho (LUDERMIR, 2021).


Avanços constantes no aprendizado de máquina têm impulsionado desenvolvimentos significativos nas tarefas agrícolas. Devido à sua capacidade de extrair características de alta dimensão de imagens de frutas, o aprendizado profundo é amplamente utilizado na detecção de

frutas e na colheita automática. Em particular, as Redes Neurais Convolucionais (CNNs) demonstraram a capacidade de atingir níveis de precisão e velocidade comparáveis aos humanos em algumas áreas de detecção de frutas e colheita automática (XIAO, 2023).

O aprendizado profundo tem mostrado excelentes capacidades para aprender recursos de imagens e é amplamente utilizado na detecção de objetos em imagens, com o objetivo de melhorar o desempenho da visão artificial na detecção de frutas (YU et al., 2019). Segundo LeCun, Bengio e Hinton (2015), o aprendizado profundo permite que modelos computacionais compostos por múltiplas camadas de processamento aprendam representações de dados em diferentes níveis de abstração. Esses métodos representam uma melhoria significativa em relação ao estado da arte em reconhecimento de fala e visual, além de descobrir estruturas complexas em grandes conjuntos de dados utilizando um algoritmo de retropropagação para ajustar os parâmetros internos da máquina.

Indira et al. (2023) descrevem as redes neurais como um tipo de Rede Neural Artificial (RNA) usada na análise de imagem, onde as imagens são exibidas em computadores como uma matriz de números de *pixels*. É crucial que o processamento de imagens em rede mantenha as relações entre os *pixels* (valores). Uma rede neural matemática é utilizada na camada de rede para preservar essa relação espacial entre os *pixels*, conforme pode ser observada na Figura 02:

FIGURA 2 - Arquitetura CNN para identificação de frutas



Fonte: Adaptado de INDIRA et al. (2023)

A Figura 2 descreve as etapas de um sistema CNN para identificação de frutas: **Input (Entrada)**: início do processo com a entrada da imagem da fruta na rede neural, representada por valores numéricos de intensidade de cor nos canais RGB. **CNN Block (Bloco Convolutivo)**: composto por camadas convolucionais onde são aplicados filtros para detectar padrões específicos na imagem, como bordas e texturas. Cada filtro produz um mapa de características (*Feature Map*) que destaca a presença desses padrões. **FNN Block (Bloco de Redes Neurais Totalmente Conectadas)**: após várias camadas convolucionais e possivelmente de *Pooling*, os *Feature Maps* são achatados em um vetor e passados para

camadas totalmente conectadas que realizam a classificação final das frutas. **Output (Saída):** a saída da CNN é uma distribuição de probabilidade sobre as classes de frutas, indicando a probabilidade de a imagem pertencer a cada categoria.

Neste estudo, foi utilizado o modelo YOLO (*You Only Look Once*), um modelo popular de detecção de objetos criado por Joseph Redmon e Ali Farhadi na Universidade de Washington em 2015. A versão YOLOv8, lançada em janeiro de 2023, apresenta desempenho superior em precisão e velocidade na detecção de objetos. Desenvolvido pela *Ultralytics*, o YOLOv8 é especializado em detecção de objetos, identificando e marcando caixas delimitadoras ao redor dos objetos em imagens ou vídeos. Ele classifica os objetos detectados em categorias com base em suas características, conseguindo detectar múltiplos objetos em uma única imagem ou quadro de vídeo com alta precisão e rapidez (ULTRALYTICS, 2024).

Conforme Ultralytics (2024), existem diferentes modelos do YOLOv8, variando em tamanho, velocidade e precisão: **YOLOv8n:** Menor e mais leve, ideal para dispositivos com menor poder de processamento ou para aplicações em tempo real onde a latência é crucial. **YOLOv8s:** Maior, com mais parâmetros, oferecendo melhor precisão na detecção de objetos. **YOLOv8m:** Tamanho intermediário entre n e s, buscando balancear velocidade e precisão. **YOLOv8l:** Maior que o s, focado em alta precisão para tarefas complexas. **YOLOv8x:** O maior e mais completo modelo, ideal para máxima precisão em aplicações exigentes.

2.1 Trabalhos Correlatos

A produção de frutas frescas enfrenta desafios significativos devido à sua perecibilidade e fragilidade, demandando atenção meticulosa durante o processo de cultivo e colheita, o que resulta em custos elevados. Reconhecendo essa demanda, diversos estudos têm explorado o potencial da Inteligência Artificial, especificamente a visão computacional, para otimizar a produção de frutas (WANG et al., 2022).

A fragilidade e perecibilidade das frutas aumentam a necessidade de cuidados intensivos durante o processo de produção, contribuindo para o alto custo desses produtos. Muitos pesquisadores estão direcionando seus esforços para integrar a Inteligência Artificial na produção de frutas, com foco na utilização da Visão Artificial para identificar frutas de forma mais eficiente (WANG et al., 2022).

Nesse contexto, Tang et al. (2023) propuseram um método inovador de reconhecimento da maturação de morangos, combinando Mask R-CNN e segmentação de região, o que resultou

em uma precisão aprimorada na identificação de diferentes estágios de maturação, contribuindo para a gestão eficaz da colheita de morangos em ambientes complexos.

Em paralelo, Afzaal et al. (2021) desenvolveram um modelo de segmentação de instâncias para identificar doenças em morangos com base no Mask R-CNN, fornecendo uma abordagem autônoma para monitorar a saúde das plantas e tomar medidas preventivas contra sete tipos de doenças.

Além disso, Wang et al. (2022) abordaram o desafio da detecção de morangos em diferentes estágios de maturação no ambiente natural, apresentando o DSE-YOLO, que incorpora técnicas de melhoria de semântica detalhada para aumentar a precisão na detecção de frutas pequenas e distinguir entre diferentes tipos de frutas.

Wise et al. (2022) exploraram o potencial da análise automatizada de imagens, orientada por aprendizado de máquina, para prever o desenvolvimento e a qualidade dos morangos, oferecendo uma abordagem promissora para a automação da colheita por meio da integração de sistemas de tomada de decisão.

Adicionalmente, Xiao et al. (2020) apresentaram um algoritmo de CNN com o modelo Resnet50 para a detecção de várias doenças do morango, fornecendo uma técnica simples e eficaz para a detecção precoce de problemas de saúde das plantas.

Kutyřev e Filippov (2023) propuseram um método para aumentar a precisão no diagnóstico de deficiência de cálcio em morangueiros, utilizando algoritmos de aprendizado de máquina, como Redes Neurais Convolucionais (CNN) YOLOv7, para detectar sinais de deficiência de cálcio nas folhas, oferecendo uma ferramenta valiosa para a gestão nutricional das plantas.

Bhujel et al. (2022) implementaram uma rede de aprendizado profundo para a segmentação e quantificação precisa da doença do mofo cinzento do morango, demonstrando a viabilidade de utilizar técnicas de visão computacional para monitorar a saúde das plantas de forma não destrutiva no ambiente natural.

Esses estudos contribuem significativamente para a pesquisa sobre a aplicação de métodos baseados em Redes Neurais Convolucionais na identificação de morangos, destacando a diversidade de abordagens e o potencial para otimizar e automatizar os processos de cultivo e colheita de frutas.

3. METODOLOGIA

Para alcançar os objetivos propostos, a pesquisa foi dividida em duas fases principais: a revisão bibliográfica e o treinamento da Rede Neural Convolucional YOLOv8m. A primeira

fase consistiu em um estudo de literatura abrangente sobre diversos temas, incluindo morangos, Visão Computacional, aprendizado de máquina, aprendizado profundo, reconhecimento e detecção de objetos, Redes Neurais Convolucionais e a aplicação específica do YOLOv8 na detecção de imagens.

A revisão bibliográfica é uma ferramenta essencial para desenvolver uma compreensão profunda dos tópicos relevantes, permitindo contextualizar, identificar lacunas e construir uma base teórica sólida (MIGUEL, 2010). A citação das principais conclusões de outros autores permite destacar a contribuição da pesquisa realizada, evidenciando comportamentos e atitudes, sejam contraditórias ou corroborativas. Confirmar os resultados obtidos por outras comunidades de pesquisa é fundamental, assim como enumerar as discrepâncias encontradas (MARCONI, 2007).

Durante este estudo de literatura, buscou-se compreender as contribuições mais recentes sobre o tema. Brown e Davis (2022) enfatizam a importância da atualização contínua das revisões bibliográficas para manter a pesquisa atualizada. Johnson e Smith (2020) sugerem que a seleção criteriosa das fontes é crucial para garantir a confiabilidade e a relevância das informações, aspectos fundamentais para a construção de uma estrutura teórica consistente.

A segunda fase consistiu na parte experimental computacional, que envolveu a coleta de um conjunto abrangente de dados de imagens de morangos, englobando vários tipos e condições de morangos para garantir a robustez e precisão no desempenho do modelo. O conjunto de dados foi obtido no repositório do Open Images Dataset V7 and Extensions, mantido pelo Google. Cada imagem é disponibilizada com anotações detalhadas, incluindo caixas delimitadoras (*bounding boxes*) e rótulos de classe, compreendendo um total de 1257 imagens anotadas. O modelo pré-treinado foi inicializado com pesos do Open Images Dataset V7 and Extensions e ajustado especificamente para a tarefa de identificação de morangos. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste, seguindo uma prática comum de validação de modelos.

O treinamento do modelo ocorreu no ambiente de desenvolvimento do *Google Colab Pro*, utilizando recursos como GPU e alta RAM para acelerar o treinamento do modelo. A linguagem de programação *Python* foi empregada juntamente com diversas bibliotecas, incluindo: **PyTorch**: Utilizado para construir e treinar modelos de Redes Neurais Convolucionais. **Ultralytics**: Ferramenta essencial para simplificar o treinamento e a avaliação de modelos de detecção de objetos, como o YOLOv8. **Pandas**, **NumPy**: Bibliotecas fundamentais para manipulação e processamento de dados. **Awscli**, **Urllib3**: Utilizados para realizar operações de *download* e gerenciamento de dados. **Tqdm**: Utilizado para exibir barras

de progresso durante operações de treinamento e avaliação. **Opencv-python:** Usado para operações de processamento de imagem, como leitura e manipulação de imagens.

Após o treinamento, foram registradas métricas como precisão da caixa (*BoxP*), revocação (*R*) e média de precisão média (*mAP50*) fornecidas pela Rede Neural Convolucional YOLOv8m. A Precisão mede a acurácia das caixas delimitadoras previstas, a Revocação avalia a capacidade do modelo de detectar todas as instâncias de morangos, e o F1-score fornece uma média harmônica de Precisão e Revocação. A métrica mAP oferece uma avaliação abrangente considerando a curva precisão-revocação em vários limiares de interseção sobre união (IoU).

Para realizar essas operações no *Google Colab*, além das bibliotecas mencionadas, foram utilizadas as seguintes: **Cv2:** Utilizado para operações de processamento de imagem. **Matplotlib.pyplot:** Utilizado para visualização de gráficos e resultados. **Os, Image:** Utilizados para operações de sistema de arquivos e manipulação de imagens. **Cv2_imshow:** Utilizado para exibir imagens dentro do ambiente de desenvolvimento do *Google Colab*, este ambiente proporcionou os recursos necessários para treinar e avaliar o modelo YOLOv8m para a detecção de morangos.

4. RESULTADOS E DISCUSSÕES

A análise dos resultados apresentados na Tabela 1 proporciona uma base para discussões acerca da eficácia do modelo e suas limitações.

TABELA 1 - Resumo treinamento do modelo de morangos

Treino	Epoch	BoxP	R	mAP50-	
				mAP50	90
1º	10	0.309	0.413	0.295	0.175
2º	70	0.525	0.479	0.447	0.301
3º	70	0.525	0.479	0.447	0.301
4º	200	0.451	0.512	0.462	0.316
5º	70	0.453	0.563	0.442	0.289
6º	70	0.478	0.58	0.449	0.29
7º	70	0.493	0.569	0.472	0.294
8º	70	0.5	0.537	0.465	0.294
9º	70	0.413	0.522	0.387	0.255
10º	70	0.472	0.522	0.422	0.279

Fonte: Elaborado pelos autores.

Inicialmente, o treinamento foi realizado por apenas 10 épocas, resultando em métricas modestas de desempenho, incluindo BoxP de 0.309, R de 0.413, mAP50 de 0.295 e mAP50-90 de 0.175. Em seguida, um segundo treinamento foi conduzido com 70 épocas, resultando em melhorias significativas em todas as métricas, com um aumento notável em BoxP, R, mAP50 e mAP50-90.

Neste ponto, conforme observado na Figura 3, foi constatado que nem todos os morangos estavam sendo identificados pelo modelo.

FIGURA 3 - Exemplo de imagem utilizada no teste



Fonte: Elaborado pelos autores.

Após observar uma estagnação no desempenho nas últimas 100 épocas de um treinamento de 200 épocas, o modelo interrompeu automaticamente o treinamento em 169 épocas, destacando sua capacidade de autoavaliação. Essa observação indica que o modelo atingiu seu limite de aprendizado e não estava mais obtendo ganhos significativos em desempenho. Apesar do aumento no número de épocas, o modelo não apresentou melhora significativa na precisão, sugerindo que o número ideal de épocas pode ter sido atingido em 70. Esta capacidade de autoavaliação é crucial para evitar *overfitting* e otimizar o tempo de treinamento.

Segundo Ying (2019), o *overfitting* é um problema fundamental no aprendizado de máquina supervisionado que impede que os modelos generalizem perfeitamente, ajustando-se excessivamente aos dados observados e não sendo eficazes em novos dados, devido ao ruído, ao tamanho limitado do conjunto de treinamento e à complexidade do classificador. Após a

observação da estagnação, foram realizados seis treinamentos adicionais de 70 épocas cada, utilizando os pesos iniciais do treino anterior como ponto de partida. Essa estratégia resultou em valores consistentes para as métricas mAP50 (entre 0.442 e 0.472) e mAP50-90 (entre 0.289 e 0.294), demonstrando a efetividade do treinamento contínuo na estabilização do desempenho do modelo.

A partir do sexto treino utilizando os pesos do resultado do treino anterior, conforme mostrado na Figura 4, observa-se que o modelo foi capaz de identificar todos os frutos na imagem teste.

FIGURA 4 - Identificação de todos os frutos pelo modelo



Fonte: Elaborado pelos autores.

Os resultados indicam que o treinamento contínuo e a utilização de pesos iniciais ajustados de treinamentos anteriores podem levar à estabilização e melhoria do desempenho do modelo YOLOv8m, especialmente na detecção de morangos. Essa abordagem permitiu alcançar métricas consistentes e uma identificação eficaz das frutas nas imagens de teste.

5. CONCLUSÃO

Este estudo forneceu uma análise detalhada do processo de treinamento da Rede Neural Convolutacional YOLOv8m para a identificação de morangos em imagens. Ao longo do treinamento, observou-se um progresso significativo no desempenho do modelo, conforme evidenciado pelas métricas de precisão da caixa (BoxP), revocação (R) e mAP50.

A capacidade do modelo de autoavaliação e intervenção automática durante o treinamento, como demonstrado pela interrupção automática do treinamento quando detectou estagnação, é um destaque significativo deste estudo. Essa capacidade permite uma utilização eficiente dos recursos computacionais, evitando o *overfitting* e otimizando o tempo de treinamento. Além disso, os treinamentos contínuos com o uso dos pesos anteriores foram fundamentais para explorar o potencial máximo do modelo. Embora os resultados dos treinamentos subsequentes tenham mostrado variações mínimas, isso indica que o modelo atingiu um ponto de saturação em seu aprendizado. Essa compreensão é crucial para evitar esforços desnecessários e focar em áreas de melhoria mais significativas.

No entanto, é importante reconhecer as limitações do modelo. Questões como variações significativas nos dados de entrada e a qualidade dos dados de treinamento podem afetar o desempenho do modelo na detecção de morangos em diferentes condições. Embora o YOLOv8m tenha demonstrado ser uma ferramenta poderosa para a detecção de morangos, este estudo identificou algumas limitações. O modelo pode ter dificuldade em lidar com variações significativas nos dados, como mudanças na iluminação ou na aparência dos morangos. Além disso, o desempenho do modelo pode ser afetado por questões como a qualidade e quantidade dos dados de treinamento.

O processo de detecção de morangos usando a Rede Neural Convolucional YOLOv8m representa um avanço significativo na agricultura de precisão porque permite a detecção rápida e precisa de morangos em vários *backgrounds*. Isso facilita a identificação e o monitoramento das frutas ao longo de seu ciclo produtivo. Além de ser capaz de distinguir frutos, o YOLOv8 pode ser treinado para detectar anomalias como doenças e pragas, o que permite que as plantações sejam protegidas rapidamente. A gestão agrícola pode usar a análise da aplicação para fazer ajustes nas práticas de cultivo para aumentar a produção e a qualidade dos morangos, melhorar a eficiência operacional e apoiar uma agricultura mais ecológica e sustentável.

Para pesquisas futuras, recomenda-se explorar técnicas adicionais de aumento de dados e considerar arquiteturas de rede alternativas para melhorar ainda mais o desempenho do modelo em cenários desafiadores. Além disso, é fundamental continuar investigando estratégias para lidar com variações nos dados e aprimorar a robustez do modelo em ambientes diversos.

Este estudo contribui para o avanço do campo da visão computacional, oferecendo insights valiosos sobre o treinamento de Redes Neurais Convolucionais para a identificação de morangos. Ao continuar a explorar e aprimorar as técnicas de modelagem e treinamento, é possível desenvolver sistemas mais eficientes e precisos para uma variedade de aplicações práticas, incluindo a automação de processos agrícolas e o aprimoramento da produção de

morangos. Essas melhorias podem levar a um aumento na eficiência e na precisão das operações agrícolas, proporcionando benefícios econômicos e sustentáveis ao setor agrícola.

AGRADECIMENTOS

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

REFERÊNCIAS

- AFZAAL, U.; BHATTARAI, B.; PANDEYA, Y. R.; LEE, J. **An instance segmentation model for strawberry diseases based on mask R-CNN**. *Sensors*, v. 21, n. 19, p. 6565, 2021.
- BACKES, A. R.; JUNIOR, J. J. d. M. S. **Introdução à visão computacional usando Matlab**. [S.l.]: Alta Books Editora, 2019.
- BHUJEL, A.; KHAN, F.; BASAK, J. K.; JAIHUNI, M.; SIHALATH, T.; MOON, B. E.; KIM, H. T. **Detection of gray mold disease and its severity on strawberry using deep learning networks**. *Journal of Plant Diseases and Protection*, v. 129, n. 3, p. 579-592, 2022.
- BONOW, S.; ANTUNES, L. E. C.; SCHWENGBER, J. E.; FLORES CANTILLANO, R. F.; UENO, B. **BRS DC Fênix, Cultivar, Morango, Variedade**. Embrapa Clima Temperado, 2023.
- BROWN, A.; DAVIS, R. **The Evolving Landscape of Literature Reviews in Contemporary Research**. *Journal of Academic Writing*, v. 12, n. 1, p. 112-128, 2022.
- CEDES – Centro de Estudos e Debates Estratégicos. Consultoria Legislativa da Câmara dos Deputados. **Perdas e desperdício de alimentos – estratégias para redução**. Série de cadernos de trabalhos e debates 3. Brasília, DF, p. 260, 2018.
- INDIRA, D. N. V. S. L. S.; GODDU, Jyothi; INDRAJA, Baisani; CHALLA, Vijaya Madhavi Lakshmi; MANASA, Bezawada. **A review on fruit recognition and feature evaluation using CNN**. *Materials Today: Proceedings*, v. 80, parte 3, p. 3438-3443, 2023. ISSN 2214-7853. Disponível em: <https://doi.org/10.1016/j.matpr.2021.07.267>. Acesso em: 9 jul. 2024.
- EMBRAPA - **Frutas e hortaliças**. Disponível em: <https://www.embrapa.br/grandes-contribuicoes-para-a-agricultura-brasileira/frutas-e-hortaliças>. Acesso em: 18 mai. 2023..
- JOHNSON, K.; SMITH, L. **Strategies for Effective Literature Review: A Comprehensive Analysis**. *Research Synthesis Methods*, v. 11, n. 4, p. 513-527, 2020.
- KUTYRĚV, A. I.; FILIPPOV, R. A. **Application of a convolutional neural network for monitoring the condition of garden strawberries**. *Euro-Northeast Agricultural Science*, v. 24, n. 4, p. 685-696, 2023.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep Learning**. Nature, v. 521, p. 436-44, 2015. Disponível em: <https://doi.org/10.1038/nature14539>. Acesso em: 9 jul. 2024.

LUDERMIR, T. B. **Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências**. Estudos Avançados, v. 35, n. 101, p. 85–94, 2021. Disponível em: <https://doi.org/10.1590/s0103-4014.2021.35101.007>. Acesso em: 9 jul. 2024.

MARCONI, M. de A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 5. ed. São Paulo: Atlas, 2007. p. 43.

MIGUEL, P. A. C. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. São Paulo: Editora Elsevier, 2010.

PBMH & PIMO - Programa Brasileiro Para A Modernização Da Horticultura & Produção Integrada De Morango. **Normas de Classificação de Morango**. São Paulo: CEAGESP, 2009. (Documentos, 33).

LIU, Q.; YAN, Q.; TIAN, J.; YUAN, K. **Principais tecnologias e aplicações na agricultura inteligente**. Journal of Physics: Conference Series, v. 1757, n. 1, fev. 2021. Disponível em: <https://doi.org/10.1088/1742-6596/1757/1/012059>. Acesso em: 9 jul. 2024.

SA, I.; GE, Z.; DAYOUB, F.; UPCROFT, B.; PEREZ, T.; McCOOL, C. **DeepFruits: A fruit detection system using deep neural networks**. Sensors, vol. 16, no. 8, article 1222, 2016.

TANG, C.; CHEN, D.; WANG, X.; NI, X.; LIU, Y.; LIU, Y.; WANG, S. **A fine recognition method of strawberry ripeness combining Mask R-CNN and region segmentation**. Frontiers in Plant Science, v. 14, 1211830, 2023.

ULTRALYTICS. **Yolov8**. Ultralytics, 2024. Disponível em: <https://docs.ultralytics.com>. Acesso em: 11 Maio 2024.

FAO - Food and Agriculture Organization of the United Nations. **Production (t)**. [dataset]. Our World in Data, 2024. Disponível em: <https://ourworldindata.org/agricultural-production#explore-data-on-agricultural-production>. Acesso em: 28 mai. 2024.

WANG, A.; QIAN, W.; LI, A.; XU, Y.; HU, J.; XIE, Y.; ZHANG, L. **NVW-YOLOv8s: An improved YOLOv8s network for real-time detection and segmentation of tomato fruits at different ripeness stages**. Computers and Electronics in Agriculture, v. 219, 108833, 2024. Disponível em: <https://doi.org/10.1016/j.compag.2024.108833>. Acesso em: 9 jul. 2024.

WANG, C.; LIU, S.; WANG, Y.; XIONG, J.; ZHANG, Z.; ZHAO, B.; HE, P. **Application of convolutional neural network-based detection methods in fresh fruit production: a comprehensive review**. Frontiers in Plant Science, v. 13, 868745, 2022.

WANG, Y.; YAN, G.; MENG, Q.; YAO, T.; HAN, J.; ZHANG, B. **DSE-YOLO: Detail semantics enhancement YOLO for multi-stage strawberry detection**. Computers and Electronics in Agriculture, v. 198, 107057, 2022.

WANG, T.; PENG, H.; CAO, Y.; XU, X.; WEI, B.; CUI, T. **TIA-YOLOv5: an improved YOLOv5 network for real-time detection of crop and weed in the field**. *Frontiers in Plant Science*, v. 13, 1091655, 2022.

WISE, K.; WEDDING, T.; SELBY-PHAM, J. **Application of automated image colour analyses for the early-prediction of strawberry development and quality**. *Scientia Horticulturae*, v. 304, 111316, 2022.

XIAO, F.; WANG, H.; XU, Y.; ZHANG, R. **Fruit Detection and Recognition Based on Deep Learning for Automatic Harvesting: An Overview and Review**. *Agronomy*, v. 13, n. 6, 1625, 2023. Disponível em: <https://doi.org/10.3390/agronomy13061625>. Acesso em: 9 jul. 2024.

XIAO, J. R.; CHUNG, P. C.; WU, H. Y.; PHAN, Q. H.; YEH, J. L. A.; HOU, M. T. K. **Detection of strawberry diseases using a convolutional neural network**. *Plants*, v. 10, n. 1, 31, 2020.

YING, X. **An Overview of Overfitting and its Solutions**. *Journal of Physics: Conference Series*, v. 1168, 2019. Disponível em: <https://doi.org/10.1088/1742-6596/1168/2/022022>. Acesso em: 9 jul. 2024.

YU, Y.; ZHANG, K.; YANG, L.; ZHANG, D. **Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN**. *Computers and Electronics in Agriculture*, v. 163, 104846, 2019. Disponível em: <https://doi.org/10.1016/j.compag.2019.06.001>. Acesso em: 9 jul. 2024.

ZHOU, X.; LEE, W. S.; AMPATZIDIS, Y.; CHEN, Y.; PERES, N.; FRAISSE, C. **Strawberry Maturity Classification from UAV and Near-Ground Imaging Using Deep Learning**. *Smart Agricultural Technology*, v. 1, 100001, 2021. Disponível em: <https://doi.org/10.1016/j.atech.2021.100001>. Acesso em: 9 jul. 2024.