



DE 14 À 19 DE OUTUBRO DE 2024
DEL 14 AL 19 DE OCTUBRE DE 2024

V SLACTIA

SIMPÓSIO LATINO-AMERICANO DE CIÊNCIA, TECNOLOGIA E INOVAÇÃO EM AGROPECUÁRIA
SIMPOSIO LATINOAMERICANO DE CIENCIA, TECNOLOGÍA E INNOVACIÓN EN LA AGROPECUARIA

INOVAÇÃO TECNOLÓGICA RURAL APLICADA

CLASSIFICAÇÃO INTELIGENTE POR IMAGEM NA COLHEITA DO MORANGO UTILIZANDO APRENDIZADO DE MÁQUINA

Vinicius Teixeira do Nascimento¹
Angel Sanchez Ramon Delgado²
Sergio Drumond Ventura³

RESUMO

O artigo explora o uso de inteligência artificial (IA) na colheita de morangos, focando na aplicação de aprendizado de máquina (machine learning) e visão computacional. A pesquisa desenvolve um modelo de classificação inteligente por imagem, utilizando redes neurais convolucionais (CNNs) para identificar o grau de maturação dos frutos. O objetivo é automatizar o processo de colheita, otimizando a precisão e eficiência. A coleta e pré-processamento de dados envolvem imagens de morangos, categorizadas conforme seu estágio de maturidade, e o modelo é treinado para reconhecer padrões visuais, como cor e textura, que indicam se o morango está pronto para ser colhido. Técnicas de aprendizado profundo, como o uso de CNNs, são fundamentais para o sucesso do sistema, e arquiteturas como a ResNet50 são mencionadas como adequadas devido à sua capacidade de lidar com grandes volumes de dados visuais. Os resultados mostram alta acurácia na classificação, com benefícios como a redução de custos de mão de obra e o aumento da qualidade dos frutos colhidos. No entanto, o artigo também reconhece desafios, como o alto custo de implementação e a complexidade técnica envolvida na manutenção e atualização dos sistemas. Conclui-se que o avanço contínuo da IA pode transformar a agricultura, promovendo colheitas mais eficientes e sustentáveis.

Palavras Chaves: Inteligência Artificial. Aprendizado de Máquina. Colheita Automatizada. Visão Computacional. Morango.

INTELLIGENT IMAGE CLASSIFICATION IN THE STRAWBERRY HARVEST USING MACHINE LEARNING

ABSTRACT

¹Doutorando do Programa de Pós-Graduação Em Ciência, Tecnologia e Inovação em Agropecuária; UFRRJ; vinicius.nascimento@ufrj.br

² Professor do Programa de Pós-Graduação Em Ciência, Tecnologia e Inovação em Agropecuária; UFRRJ; asanchez@ufrj.br

³ Professor do Departamento de Matemática; UFRRJ; ventura@ufrj.br

The article explores the use of artificial intelligence (AI) in strawberry harvesting, focusing on the application of machine learning and computer vision. The research develops an intelligent image classification model, using convolutional neural networks (CNNs) to identify the degree of fruit ripeness. The objective is to automate the harvesting process, optimizing precision and efficiency. Data collection and pre-processing involves images of strawberries, categorized according to their stage of maturity, and the model is trained to recognize visual patterns, such as color and texture, that indicate whether the strawberry is ready to be harvested. Deep learning techniques such as the use of CNNs are fundamental to the system's success, and architectures such as ResNet50 are mentioned as suitable due to their ability to handle large volumes of visual data. The results show high classification accuracy, with benefits such as reduced labor costs and increased quality of harvested fruits. However, the article also recognizes challenges, such as the high cost of implementation and the technical complexity involved in maintaining and updating systems. It is concluded that the continued advancement of AI can transform agriculture, promoting more efficient and sustainable harvests.

Keywords: Artificial intelligence. Machine Learning. Automated Harvest. Computer Vision. Strawberry.

CLASIFICACIÓN INTELIGENTE DE IMÁGENES EN LA COSECHA DE FRESA MEDIANTE APRENDIZAJE MÁQUINA

RESUMEN

El artículo explora el uso de la inteligencia artificial (IA) en la cosecha de fresas, centrándose en la aplicación del aprendizaje automático y la visión por computadora. La investigación desarrolla un modelo inteligente de clasificación de imágenes, utilizando redes neuronales convolucionales (CNN) para identificar el grado de madurez de la fruta. El objetivo es automatizar el proceso de recolección, optimizando la precisión y la eficiencia. La recopilación y el preprocesamiento de datos implican imágenes de fresas, categorizadas según su etapa de madurez, y el modelo está entrenado para reconocer patrones visuales, como el color y la textura, que indican si la fresa está lista para ser cosechada. Las técnicas de aprendizaje profundo, como el uso de CNN, son fundamentales para el éxito del sistema, y arquitecturas como ResNet50 se mencionan como adecuadas debido a su capacidad para manejar grandes volúmenes de datos visuales. Los resultados muestran una alta precisión de clasificación, con beneficios como menores costos de mano de obra y mayor calidad de los frutos cosechados. Sin embargo, el artículo también reconoce desafíos, como el alto costo de implementación y la complejidad técnica que implica el mantenimiento y actualización de los sistemas. Se concluye que el avance continuo de la IA puede transformar la agricultura, promoviendo cosechas más eficientes y sostenibles.

Palabras clave: Inteligencia artificial. Aprendizaje automático. Cosecha automatizada. Visión por computadora. Fresa.

INTRODUÇÃO

A agricultura tem passado por uma verdadeira revolução tecnológica nas últimas décadas, impulsionada por inovações em diversas áreas, como automação, internet das coisas

(IoT), robótica e, mais recentemente, inteligência artificial (IA). No contexto da fruticultura, o morango se destaca como uma das frutas mais cultivadas e consumidas mundialmente, devido ao seu alto valor nutricional, sabor e versatilidade culinária. Contudo, o processo de colheita do morango, tradicionalmente manual, envolve desafios significativos, tais como a delicadeza do fruto, a variabilidade em seu grau de maturação e a necessidade de precisão na seleção dos melhores espécimes. Tais fatores têm incentivado o desenvolvimento de novas soluções tecnológicas que possam aumentar a eficiência e a precisão desse processo (Borba, 2022).

Nesse cenário, o uso de inteligência artificial (IA) aplicada à classificação por imagem surge como uma alternativa promissora para otimizar a colheita do morango. Técnicas de aprendizado de máquina (machine learning), em especial aquelas voltadas para o reconhecimento de padrões visuais, podem ser utilizadas para identificar e classificar o estágio de maturação dos frutos, além de determinar quais morangos estão prontos para a colheita. A automação desse processo oferece uma série de vantagens, incluindo a redução de custos com mão de obra, aumento da produtividade e garantia de que apenas os frutos de qualidade ideal sejam colhidos, reduzindo perdas e melhorando a qualidade do produto final para o consumidor (Viezzler, 2022).

Este artigo explora o uso de aprendizado de máquina para a classificação inteligente por imagem na colheita de morangos, com foco no desenvolvimento e aplicação de algoritmos que possam identificar o grau de maturação de cada fruto. Ao longo do texto, serão discutidas as principais técnicas de IA e visão computacional envolvidas nesse processo, bem como os desafios e as oportunidades dessa abordagem na agricultura moderna.

Segundo Henrique et al. (1999), a colheita de morangos apresenta peculiaridades que tornam o processo particularmente complexo, mesmo para trabalhadores experientes. Os morangos são frutas delicadas e altamente perecíveis, o que exige cuidados extras tanto na colheita quanto no transporte e armazenamento. Além disso, o momento exato da colheita é crucial para garantir que o fruto tenha a melhor qualidade em termos de sabor, textura e valor nutricional. Morangos colhidos precocemente podem ser insossos e duros, enquanto aqueles que permanecem no campo por tempo excessivo podem apodrecer ou sofrer danos devido à exposição a pragas e condições climáticas adversas. Outro fator importante é a irregularidade no amadurecimento dos morangos, que pode variar significativamente dentro de uma mesma plantação. Ao contrário de culturas como o trigo ou o milho, em que a colheita pode ser realizada de forma homogênea, os morangos amadurecem de forma gradativa, o que significa que, em um único canteiro, alguns frutos podem estar prontos para a colheita, enquanto outros ainda precisam de mais tempo para atingir a maturidade ideal. Tradicionalmente, isso exige que

os trabalhadores retornem várias vezes ao mesmo canteiro, aumentando os custos com mão de obra e reduzindo a eficiência operacional. Além disso, a variabilidade no tamanho, formato e cor dos morangos representa outro desafio. Embora existam padrões estabelecidos para determinar quando o fruto está maduro o suficiente para a colheita, essas características podem variar de acordo com a variedade da planta, as condições de cultivo e o microclima local. Isso torna o processo de classificação uma tarefa desafiadora, que depende não apenas do julgamento visual dos trabalhadores, mas também de sua experiência e habilidade em diferenciar frutos prontos para a colheita daqueles que ainda precisam de mais tempo no campo.

A visão computacional é uma área da inteligência artificial que visa ensinar as máquinas a "verem" e interpretar imagens de maneira semelhante aos humanos. Na agricultura, o uso de visão computacional tem ganhado destaque como uma ferramenta capaz de melhorar a eficiência e a precisão em diferentes estágios da cadeia produtiva, desde o monitoramento de safras até a colheita automatizada. No caso específico da colheita de morangos, a visão computacional, combinada com algoritmos de aprendizado de máquina, pode ser usada para identificar automaticamente o estágio de maturação dos frutos com base em características visuais, como cor, tamanho, textura e até mesmo a presença de defeitos ou doenças (Marengoni, 2009).

A aplicação da visão computacional na colheita de morangos envolve a captura de imagens dos frutos em tempo real, seja por câmeras estáticas instaladas no campo ou por sistemas móveis acoplados a robôs ou drones. As imagens são, então, processadas por algoritmos que analisam cada morango individualmente e classificam seu estágio de maturação com base em critérios pré-estabelecidos. Isso permite que a colheita seja realizada de maneira seletiva, colhendo apenas os frutos que estão prontos, enquanto os outros permanecem no campo para amadurecer adequadamente (Santos, 2020).

O aprendizado de máquina é uma subárea da inteligência artificial que envolve a criação de modelos capazes de aprender e melhorar automaticamente a partir de dados. Em vez de serem explicitamente programados para realizar uma tarefa específica, os algoritmos de aprendizado de máquina são "treinados" usando grandes volumes de dados rotulados. No caso da colheita de morangos, o treinamento de um modelo de aprendizado de máquina pode envolver o uso de milhares ou até milhões de imagens de morangos em diferentes estágios de maturação. Cada imagem é rotulada manualmente ou automaticamente para indicar se o fruto está pronto para ser colhido ou não (Mornad, 2003).

Existem várias abordagens de aprendizado de máquina que podem ser aplicadas à classificação de morangos, sendo que uma das mais promissoras é o aprendizado profundo

(deep learning). Redes neurais profundas, em particular, têm mostrado um desempenho excepcional em tarefas de reconhecimento de padrões visuais. Essas redes são compostas por várias camadas de neurônios artificiais que processam as informações visuais em diferentes níveis de abstração. Nas camadas iniciais, a rede aprende a identificar características simples, como bordas e texturas; nas camadas mais profundas, ela é capaz de reconhecer padrões mais complexos, como a forma e a cor de um morango maduro (Cerri, 2019).

Um dos tipos mais comuns de redes neurais aplicadas à visão computacional é a rede neural convolucional (CNN). As CNNs são particularmente eficazes na análise de imagens porque utilizam operações de convolução que permitem à rede detectar padrões em pequenas regiões da imagem, e depois combinar essas informações para formar uma visão completa do objeto. Para a classificação de morangos, as CNNs podem ser treinadas para identificar as características visuais que indicam se o fruto está maduro ou não. Essas características podem incluir não apenas a cor vermelha brilhante, que é um indicativo de maturidade, mas também o formato e a textura da superfície do morango, que podem fornecer pistas adicionais sobre sua qualidade (Peixoto, 2023).

O processo de treinamento de um modelo de aprendizado de máquina para a classificação de morangos envolve várias etapas. Primeiramente, é necessário coletar um conjunto robusto de dados, composto por imagens de morangos em diferentes condições de iluminação, ângulos e estágios de maturação. Essas imagens são rotuladas de forma a indicar o estágio de amadurecimento de cada fruto. Em seguida, o modelo é treinado utilizando essas imagens, ajustando os parâmetros internos da rede neural para minimizar o erro na classificação.

Uma vez que o modelo tenha sido treinado, ele pode ser aplicado em um ambiente real, onde é necessário garantir que o sistema funcione de maneira eficaz sob condições variáveis, como luz solar direta, sombras e diferentes condições meteorológicas. Além disso, a robustez do modelo deve ser testada para garantir que ele possa lidar com variações no tamanho e formato dos frutos, além de possíveis interferências de outras plantas ou objetos presentes no campo.

A aplicação de inteligência artificial, especificamente de aprendizado de máquina, na colheita de morangos oferece uma série de vantagens. Além de reduzir a dependência de mão de obra humana, o que é especialmente relevante em países com altos custos trabalhistas, essa tecnologia permite que a colheita seja realizada com maior precisão e consistência. O uso de sistemas automatizados pode também resultar em menos desperdício de frutos e maior controle

sobre o ponto exato de maturidade em que cada morango é colhido, garantindo um produto final de maior qualidade.

DESENVOLVIMENTO


Serão abordados os processos técnicos que compõem a criação de um modelo de aprendizado de máquina voltado para a classificação inteligente por imagem na colheita de morangos, detalhando como será feita a modelagem e especificando o software e as linguagens de programação utilizadas. A modelagem será realizada com o uso de redes neurais convolucionais (CNNs), uma técnica amplamente adotada para tarefas de reconhecimento de imagens e visão computacional. Serão também apresentados os métodos de coleta e pré-processamento dos dados, as etapas de construção e treinamento do modelo, bem como a validação e a avaliação do desempenho. A sustentabilidade também é um aspecto importante a ser considerado. A automação e a otimização dos processos agrícolas, como a colheita seletiva de frutos maduros, podem reduzir o desperdício de recursos, como água e insumos agrícolas, além de minimizar o impacto ambiental associado ao cultivo extensivo de morangos. Em um cenário global de crescente demanda por alimentos e de desafios ambientais, o uso de IA na agricultura pode contribuir significativamente para a criação de um sistema agrícola mais sustentável e eficiente (Munzlinger, 2023).

Uma rede neural convolutiva (CNN) é um tipo de rede neural projetada para processamento de dados que têm uma estrutura de grade, como imagens. Ela é composta por camadas convolucionais que aplicam filtros (ou kernels) sobre os dados de entrada para extrair características importantes, como bordas, texturas e padrões. Essas camadas reduzem a dimensionalidade e capturam hierarquias de características de baixo nível a alto nível, permitindo que a rede aprenda representações complexas. As CNNs são amplamente utilizadas em tarefas como reconhecimento de imagens, visão computacional e processamento de vídeo devido à sua capacidade de identificar padrões espaciais e visuais com alta eficiência.

A aplicação de aprendizado de máquina na colheita de morangos oferece inúmeros benefícios para os agricultores e para a indústria como um todo. Primeiramente, a automação do processo de colheita pode resultar em uma redução substancial de custos com mão de obra, um dos principais desafios enfrentados por agricultores em diversas partes do mundo. Em muitos países, a escassez de trabalhadores rurais e o aumento dos custos trabalhistas têm tornado a colheita manual cada vez mais cara e menos sustentável. Com a utilização de robôs

ou drones equipados com sistemas de IA, a colheita pode ser realizada de maneira mais rápida, precisa e econômica, reduzindo a dependência de trabalhadores sazonais.

Figura 1 – Arquitetura Simples de uma CNN



Fonte: Souza, 2023

O primeiro passo essencial na criação de um sistema de classificação inteligente por imagem é a coleta de dados. Para o contexto da colheita de morangos, esses dados consistirão principalmente em imagens de morangos em diferentes estágios de maturação, variando desde morangos ainda verdes até aqueles maduros e prontos para a colheita. A qualidade do modelo depende diretamente da diversidade e representatividade desse conjunto de imagens.

As imagens que usaremos como base no nosso trabalho foram obtidas através da Kaggle, que é uma plataforma da comunidade e de aprendizado de ciência de dados, onde estas já se apresentavam classificadas como “Pickable” (maduro) e “Unpickable” (imaturo), o primeiro apresenta 263 imagens de morangos que estão em condições de serem colhidos e o segundo apresenta 258 imagens de morango que não estão com condições próprias para colheita, totalizando 521 imagens que serão inseridas no nosso banco de dados já classificadas.

É crucial que essas imagens estejam sob diferentes condições de iluminação e ângulos, garantindo que o modelo seja capaz de lidar com as variações naturais do ambiente agrícola, como sombras, reflexos, luz solar direta e a presença de outras plantas. Além disso, as imagens são de alta resolução, para garantir que os detalhes visuais relevantes, como permitir que a textura da superfície do morango possa ser capturada e analisada pelo modelo.

Uma vez coletadas e rotuladas as imagens, o próximo passo é o pré-processamento dos dados. O pré-processamento garante que as imagens estejam em um formato adequado para serem processadas pelo modelo de aprendizado de máquina. As etapas de pré-processamento que foram realizadas foram redimensionamento, normalização e aumento dos dados. O redimensionamento é o procedimento onde todas as imagens devem ser redimensionadas para uma dimensão fixa, de modo que possam ser processadas em lotes durante o treinamento, nosso caso transformamos as imagens na resolução full hd (1920x1080p). Já na normalização os

valores dos pixels das imagens (que variam de 0 a 255), são normalizados no intervalo de [0,1], com o objetivo de facilitar o aprendizado do modelo, dividindo os valores. E por último o aumento do dados, também chamado de Data Augmentation, que consiste em uma técnica para aumento de dados sendo aplicadas, incluindo rotações aleatórias, ajustes de brilho e contraste, e pequenas distorções nas imagens, aumentando a diversidade do conjunto de dados sem a necessidade de coletar mais imagens, melhorando a generalização do modelo e evitando overfitting, nosso caso aumentamos os dados em 10 vezes.

Para a tarefa de classificação de imagens de morangos, a arquitetura de redes neurais convolucionais (CNNs) é a mais adequada, devido à sua capacidade de detectar padrões visuais complexos em imagens. As CNNs são compostas por camadas convolucionais, que processam pequenas regiões da imagem, e camadas de pooling, que reduzem a dimensionalidade dos dados, além de camadas totalmente conectadas, que realizam a classificação final. Uma das arquiteturas de CNN mais utilizadas para tarefas de classificação de imagens é a ResNet (Residual Network), que introduz o conceito de conexões residuais, permitindo que redes muito profundas sejam treinadas de forma eficaz. Outra alternativa é o MobileNet, que é mais leve e otimizado para dispositivos móveis, o que pode ser interessante em um ambiente agrícola onde o hardware pode ter limitações de processamento e energia. Para iniciar o desenvolvimento, será utilizada a arquitetura ResNet50, que oferece um bom equilíbrio entre profundidade e desempenho. Esta arquitetura contém 50 camadas de neurônios e é amplamente reconhecida por sua capacidade de extrair características visuais complexas (Li, 2024).

O desenvolvimento do modelo de aprendizado de máquina foi feito utilizando linguagens de programação amplamente adotadas no campo da inteligência artificial e framework especializados em redes neurais. O Python é a escolha natural para essa tarefa, devido à sua vasta coleção de bibliotecas e facilidade de uso, os frameworks (bibliotecas) que foram utilizados nesse trabalho foram o TensorFlow, Kera, OpenCV, Panda e NumPy.

O TensorFlow é uma das bibliotecas mais populares para aprendizado de máquina e aprendizado profundo, desenvolvida pelo Google, ela oferece uma plataforma flexível e poderosa para a construção e treinamento de redes neurais convolucionais. Com ele é possível treinar modelos complexos, realizar inferências e otimizar o desempenho em dispositivos diferentes, incluindo GPUs e TPUs.

O Keras é uma API de alto nível integrada ao TensorFlow, que facilita a construção e o treinamento de redes neurais, é conhecido por sua simplicidade e rapidez no desenvolvimento de protótipos, permitindo definir arquiteturas de CNN de forma rápida e eficiente.

Já o OpenCV, embora não seja um framework de aprendizado de máquina, o OpenCV será utilizado para manipulação de imagens durante o pré-processamento, ele oferece funções para redimensionamento, normalização e transformação de imagens, sendo uma ferramenta essencial no pipeline de visão computacional.

Por fim, o Pandas e NumPy são Bibliotecas fundamentais para a manipulação de dados. O Pandas será usado para o gerenciamento das etiquetas e metadados das imagens, enquanto o NumPy fornecerá suporte para operações matemáticas e manipulação de arrays numéricos, que são essenciais para o funcionamento eficiente dos modelos.

O modelo de aprendizado de máquina será estruturado em três fases principais: a fase convolucional, a fase de pooling e a fase de classificação.

Nas camadas convolucionais, o modelo extrai características relevantes das imagens, como bordas, texturas e padrões de cores. Cada camada convolucional aplica diferentes filtros que destacam características específicas dos morangos, permitindo que o modelo aprenda a distinguir entre morangos maduros e imaturos com base em padrões visuais. Por exemplo, a primeira camada convolucional pode aprender a identificar as bordas externas do morango, enquanto as camadas subsequentes podem identificar a textura da superfície e a coloração vermelha que indica maturidade.

A fase de pooling reduz a dimensionalidade dos dados, diminuindo a quantidade de informações processadas nas próximas camadas, sem perder características importantes. O tipo de pooling mais comum é o max pooling, que retém o valor máximo em uma pequena região da imagem. Isso ajuda a tornar o modelo mais robusto a pequenas variações na posição e orientação dos morangos.

Após as camadas convolucionais e de pooling, as informações extraídas da imagem passam por uma ou mais camadas totalmente conectadas (fully connected layers), que realizam a classificação final. A última camada do modelo será uma camada softmax, que atribui probabilidades a cada classe de maturação (imaturo, parcialmente maduro ou maduro). O modelo, então, prevê a classe com a maior probabilidade como o estágio de maturação do morango.

O treinamento do modelo envolve ajustar os pesos das conexões neurais com base nos erros cometidos durante a previsão. Esse processo é feito usando o algoritmo de backpropagation e um otimizador como o Adam, que atualiza os pesos para minimizar a função de perda. A função de perda escolhida para o problema de classificação será a categorical crossentropy, adequada para tarefas de classificação com múltiplas classes.

Durante o treinamento, o conjunto de dados será dividido em três partes: Treinamento (80%): usado para ajustar os pesos do modelo; Validação (10%): usado para avaliar o desempenho do modelo durante o treinamento e evitar overfitting; Teste (10%): usado para avaliar o desempenho final do modelo após o término do treinamento (Cavalcante, 2023).

O treinamento será realizado em lotes (batch training), onde múltiplas imagens são processadas simultaneamente em cada iteração. O tamanho do lote será definido de acordo com a capacidade de memória da GPU, sendo comum o uso de lotes de 32 ou 64 imagens.

Para evitar o overfitting, que ocorre quando o modelo se ajusta excessivamente ao conjunto de treinamento e não generaliza bem para novos dados, serão aplicadas técnicas de regularização e aumento de dados. O aumento de dados (data augmentation), já mencionado anteriormente, será crucial para ampliar a diversidade do conjunto de imagens sem a necessidade de coletar mais dados. Além disso, será implementada a técnica de dropout, que desativa aleatoriamente uma porcentagem dos neurônios durante o treinamento, forçando o modelo a aprender representações mais robustas e generalizáveis.

Após o treinamento, o desempenho do modelo será avaliado em um conjunto de dados de teste. A acurácia será a principal métrica utilizada, indicando a porcentagem de imagens corretamente classificadas. No entanto, outras métricas também serão consideradas, como a precisão, recall e o F1-score, que são particularmente úteis em situações onde as classes estão desbalanceadas.

Uma matriz de confusão (Quadro 1) foi gerada para avaliar detalhadamente o desempenho do modelo em cada classe, permitindo visualizar quantas imagens foram classificadas corretamente e onde ocorreram os erros de classificação, indicando se o modelo está tendo dificuldades em distinguir entre morangos maduros e imaturos.

Quadro 1 – A matriz de confusão comparando com o resultado esperado

		Classe Esperada	
		Maturo	Imaturo
Classe Prevista	Maturo	262 Verdadeiro Positivo	1 Falso Positivo
	Imaturo	2 Falso Negativo	256 Verdadeiro Negativo

Fonte: Desenvolvido pelo Autor

Tivemos uma acurácia de 99,42%, este é o é a quantidade de acertos do nosso modelo dividido pelo total da amostra. Já para a precisão tivemos 99,61%, a precisão refere-se a de todos os dados classificados como positivos, quantos são realmente positivos. No recall, obtivemos o

valor de 99,24% representando a qual a porcentagem de dados classificados como positivos comparado com a quantidade real de positivos que existem em nossa amostra. Por fim, o F1-score de 99,42% representando a essa métrica uma precisão e recall afim de trazer um número único que determine a qualidade geral do nosso modelo.

A criação de um modelo de aprendizado de máquina para a classificação de morangos com base em imagens envolve várias etapas interdependentes, desde a coleta e preparação de dados até a validação e implementação do modelo em um ambiente real. Utilizando técnicas avançadas de visão computacional e aprendizado profundo, é possível desenvolver um sistema eficiente e preciso, capaz de melhorar significativamente o processo de colheita automatizada de morangos. A escolha de softwares, linguagens e frameworks robustos, como Python, TensorFlow e Keras, garante que o desenvolvimento seja feito de forma otimizada e escalável (Ramasubramanian, 2019).

Uma vez que o modelo tenha sido treinado e validado, ele pode ser implementado em sistemas de colheita automatizada no campo. O modelo será integrado a um sistema robótico ou drones equipados com câmeras que capturam imagens dos morangos em tempo real. A partir dessas imagens, o modelo será capaz de determinar quais morangos estão prontos para a colheita, permitindo que o sistema automatizado colha apenas os frutos maduros. Esse tipo de implementação pode aumentar significativamente a eficiência da colheita, reduzindo a dependência de mão de obra humana e garantindo que apenas os frutos de melhor qualidade sejam colhidos, resultando em uma redução de perdas e aumento da produtividade.

CONCLUSÕES

O uso de tecnologias emergentes, como a inteligência artificial (IA) e o aprendizado de máquina, tem se mostrado cada vez mais relevante em diversas indústrias, e a agricultura não é exceção. A adoção dessas tecnologias na colheita automatizada de morangos, por meio da classificação inteligente baseada em imagens, representa um avanço significativo para o setor agrícola. O presente trabalho teve como objetivo apresentar um modelo eficiente de classificação de morangos com o uso de redes neurais convolucionais (CNNs), detalhando todas as etapas do processo, desde a coleta e preparação dos dados até o desenvolvimento, treinamento e validação do modelo. Esse tipo de implementação pode aumentar significativamente a eficiência da colheita, reduzindo a dependência de mão de obra humana e

garantindo que apenas os frutos de melhor qualidade sejam colhidos, resultando em uma redução de perdas e aumento da produtividade.

A qualidade dos frutos colhidos tende a aumentar com a automação. O sistema proposto, baseado em redes neurais convolucionais, é capaz de classificar com precisão o estágio de maturação dos morangos, garantindo que apenas aqueles que atingiram o ponto ideal de colheita sejam selecionados. Isso resulta em um produto final de melhor qualidade para os consumidores, uma vez que os morangos colhidos no momento certo têm maior probabilidade de apresentar um melhor sabor, textura e valor nutricional.

Outro benefício importante é a redução de perdas pós-colheita. Quando os morangos são colhidos manualmente, há uma margem significativa de erro, com frutos sendo colhidos cedo demais ou tarde demais. Frutos imaturos podem não amadurecer adequadamente após a colheita, enquanto os morangos colhidos tardiamente podem apresentar sinais de deterioração ou serem mais vulneráveis a danos durante o transporte. A colheita automatizada e precisa, proporcionada pela IA, pode minimizar essas perdas e aumentar a eficiência da cadeia produtiva como um todo.

Apesar dos inúmeros benefícios associados ao uso de IA na colheita de morangos, ainda existem desafios significativos que precisam ser enfrentados para que essa tecnologia possa ser amplamente adotada. Um dos principais obstáculos é o alto custo inicial de implementação dos sistemas automatizados. O desenvolvimento e a integração de hardware e software, como robôs agrícolas, câmeras de alta resolução e modelos de aprendizado de máquina, exigem investimentos consideráveis, o que pode ser um impeditivo para pequenos e médios agricultores.

Além disso, a complexidade técnica envolvida no desenvolvimento de sistemas de visão computacional robustos é outro desafio. Embora as redes neurais convolucionais sejam extremamente eficazes na classificação de imagens, elas requerem uma quantidade significativa de dados para o treinamento adequado. A coleta, rotulagem e pré-processamento dessas imagens são etapas que demandam tempo e esforço, especialmente em ambientes agrícolas, onde as condições podem ser imprevisíveis e variáveis. Fatores como mudanças na iluminação, presença de sombras, variações no tamanho e formato dos frutos, bem como interferências de outros elementos do ambiente, podem dificultar a acuracidade do modelo.

Outro ponto importante é a manutenção e atualização dos sistemas automatizados. A IA e os algoritmos de aprendizado de máquina estão em constante evolução, o que significa que os modelos desenvolvidos precisam ser atualizados periodicamente para manter a precisão e a eficiência. Além disso, os sistemas robóticos usados para a colheita devem ser mantidos e

calibrados regularmente para garantir que funcionem corretamente em diferentes condições do campo.

Apesar desses desafios, o futuro da IA na agricultura é extremamente promissor. Com o avanço contínuo das tecnologias de aprendizado profundo e visão computacional, espera-se que os sistemas de colheita automatizada se tornem mais acessíveis e eficazes. Iniciativas de pesquisa e desenvolvimento, combinadas com políticas públicas que incentivem a adoção de tecnologias emergentes no campo, podem acelerar a transição para uma agricultura mais automatizada e baseada em dados. As parcerias entre empresas de tecnologia e agricultores podem desempenhar um papel crucial na disseminação dessas inovações. A criação de soluções personalizadas e adaptáveis às necessidades específicas de cada região agrícola pode facilitar a adoção de IA em larga escala. Por exemplo, sistemas de colheita automatizada podem ser adaptados para funcionar com diferentes variedades de morangos e em diferentes tipos de solo e clima, garantindo que a tecnologia seja relevante para uma ampla gama de produtores.

No longo prazo, a agricultura de precisão, que utiliza sensores, drones e IA para monitorar e gerenciar plantações de maneira detalhada, tem o potencial de transformar completamente a forma como os alimentos são cultivados, colhidos e distribuídos. A colheita automatizada de morangos é apenas um exemplo de como a IA pode ser aplicada para aumentar a eficiência, reduzir desperdícios e melhorar a qualidade dos alimentos.

Este trabalho apresentou uma abordagem inovadora para a colheita de morangos utilizando aprendizado de máquina e visão computacional, com foco no desenvolvimento de um modelo de classificação inteligente por imagem capaz de identificar o estágio de maturação dos frutos. Através do uso de redes neurais convolucionais (CNNs) e técnicas de processamento de imagens, foi possível criar um sistema eficiente que pode ser implementado em ambientes agrícolas reais para automatizar o processo de colheita.

Os resultados obtidos mostram que a IA pode desempenhar um papel transformador na agricultura, oferecendo soluções que aumentam a produtividade, reduzem os custos e melhoram a qualidade dos alimentos. No entanto, desafios relacionados ao custo, à complexidade técnica e à manutenção dos sistemas ainda precisam ser superados para que essa tecnologia se torne amplamente acessível. O uso de IA na colheita de morangos representa um passo importante em direção a uma agricultura mais eficiente e sustentável. Com o avanço contínuo da tecnologia e o desenvolvimento de soluções personalizadas para o campo, espera-se que a colheita automatizada se torne uma realidade comum em muitas plantações ao redor do mundo, contribuindo para um futuro mais produtivo e resiliente para a agricultura global.

REFERÊNCIAS BIBLIOGRÁFICAS

BORBA, M. C. **Gestão no meio agrícola com o apoio da Inteligência Artificial: uma análise da digitalização da agricultura.** Revista em Agronegocio e Meio Ambiente, v. 15, n. 3, p. 1-22, 2022.

CAVALCANTE, E.S., VASCONCELOS, L. G.S., BRITO, R.P., BRITO, K. D. **Soft sensor baseado em redes neurais artificiais para a predição de temperaturas de partes da carroceria em estufas de secagem e cura de pintura automotiva.** GeSec: Revista de Gestao e Secretariado, v. 14(4), 2023.

CERRI, R. et al. **Aprendizado de máquina: breve introdução e aplicações.** Cadernos de Ciência & Tecnologia, v. 34, n. 3, p. 297-313, 2019.

HENRIQUE, C. M.; CEREDA, M. P. **Utilização de biofilmes na conservação pós-colheita de morango (Fragaria Ananassa Duch) cv IAC Campinas.** Food Science and Technology, v. 19, p. 231-233, 1999.

JÚNIOR, J. F. C., REIS NETO, R. A., DE GUSMÃO, V. R., MENEZES, N. L. B., SILVA, M. I., SANTOS, L. S. R., REINOSO, L. F. **O futuro da aprendizagem com a inteligência artificial aplicada à educação 4.0.** Revista Educação, Humanidades e Ciências Sociais, e94, 2023.

LI, C., POLLING, M., CAO, L., GRAVENDEEL, B., & VERBEEK, F. J. **Analysis of automatic image classification methods for Urticaceae pollen classification.** Neurocomputing, v. 522, p. 181-193, 2023.

MARENGONI, M.; STRINGHINI, S. **Tutorial: Introdução à visão computacional usando opencv.** Revista de Informática Teórica e Aplicada, v. 16, n. 1, p. 125-160, 2009.

MONARD, M. C.; BARANAUSKAS, J. A.. **Conceitos sobre aprendizado de máquina. Sistemas inteligentes-Fundamentos e aplicações,** v. 1, n. 1, p. 32, 2003.

MUNZLINGER, C., YEPES, I., RIEDER, R. **Uso de uma rede neural convolucional para análise de exames de radiografia de pulmão com detecção de covid-19, pneumonia e tuberculose.** In Anais Estendidos do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde (pp. 25-30). SBC.2023.

PEIXOTO, E.B.A. **Uso de redes neurais convolucionais para detecção automática de estradas a partir de imagens aéreas obtidas por veículos não tripulados.** Revista Foco (Interdisciplinary Studies Journal), v. 16, n. 7, 2023.

Potrimba, P. (13 de março de 2024). **O que é ResNet-50?**. Blog Roboflow: Disponível em: <https://blog.roboflow.com/what-is-resnet-50/>, Acesso em: 20 set. 2024.

RAMASUBRAMANIAN, K., SINGH, A., RAMASUBRAMANIAN, K., SINGH, A. **Deep learning using keras and tensorflow.** Machine Learning Using R: With Time Series and Industry-Based Use Cases in R, p. 667-688. 2019.

SANTOS, T.T.; BARBEDO, J.G.A; TERNES,S.; CAMARGO NETO, J.; KOENIGKAN, L.V.; SOUZA,K.X.S. **Visão Computacional na Agricultura; Agricultura digital: pesquisa, desenvolvimento e inovação de cadeias produtivas,** Embrapa, 2020.

SOUZA, V. S. S. **Introdução à interpretabilidade de redes neurais convolucionais.** Monografia (Graduação em Ciência da Computação) - Instituto de Ciências Exatas e Biológicas, Universidade Federal de Ouro Preto, Ouro Preto, 2023.

VIEZZER, M. **O uso da inteligência artificial pelo sistema jurídico brasileiro, classificação da inteligência artificial e análise de seu uso.** Revista Ibero-Americana de Humanidades, Ciências e Educação, v. 8, n. 1, p. 1193-1213, 2022.