

SIMULAÇÃO DE UM CONTROLE DE ESTOQUE UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Pedro Henrique C. Da Silva¹, Ivan Lucas Arantes²

IFSP - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Rod. Pres. Dutra, km 145 - s/n - Jardim Diamante - 12223-201 - São José dos Campos – SP, Brasil, ¹Discente no curso de Engenharia de controle e Automação - p.canoas@aluno.ifsp.edu.br, ²Docente: ivanlucas@ifsp.edu.br

Resumo

A proposta deste trabalho consiste no desenvolvimento, análise e aplicação de uma IA (*Inteligência Artificial*) utilizando a metodologia YOLOv8 para o reconhecimento de imagens de peças veiculares. O objetivo é realizar o controle de estoque de um almoxarifado em tempo real e da maneira mais rápida possível. Ao longo deste trabalho, serão abordados alguns aspectos do projeto, tais como: métodos para o desenvolvimento completo da programação, treinamento do modelo de inteligência artificial, validação do mesmo com imagens de um estoque, e técnicas para o aprimoramento do modelo. Espera-se uma comparação entre os resultados obtidos em termos de assertividade e velocidade de processamento, em decorrência da variação da quantidade de imagens e épocas de treinamento, destacando-se características distintas resultantes, porém com ganhos expressivos de acordo com a aplicação desejada.

Palavras-chave: Inteligência Artificial. Controle de estoque. Programação. Reconhecimento de imagens.

Área do Conhecimento: Engenharias - Engenharia Mecatrônica

Introdução

O controle eficaz de estoque é um componente crítico para o sucesso operacional de lojas e fábricas. Gerenciar adequadamente os níveis de estoque é essencial para garantir a disponibilidade de produtos para os clientes, manter a qualidade dos ativos da empresa e reduzir os riscos associados ao armazenamento excessivo ou à obsolescência de estoque (DANDARO; MARTELLO, 2015).

Nesse contexto, o avanço da indústria 4.0 tem sido um catalisador para a transformação de operações tradicionais, especialmente com a incorporação da Inteligência Artificial (IA) nas demandas diárias. A IA ultrapassou sua função inicial como mera ferramenta de otimização de processos, tornando-se uma necessidade para as empresas que buscam condicionar sua competitividade e liderança no mercado. Esta evolução destaca a importância de adotar tecnologias inovadoras na gestão de estoque, onde a precisão e a eficiência são cruciais. Walther (2024) cita o exemplo da empresa Amazon.com, Inc que utiliza a inteligência artificial para prever demanda, analisar a saída e entrada de seus produtos. Isso faz com que a Amazon aprimore seus estoques e mantenha a quantidade correta de produto, sem excessos ou escassez. Além disso, a empresa de e-commerce estadunidense utiliza uma ferramenta da IA que prevê a demanda futura, otimizando seu estoque, aumentando a satisfação de seus clientes e garantindo maiores lucros para a empresa.

Entre as tecnologias emergentes, YOLOv8 (*You Only Look Once*, em português: “Só se vive uma vez”), a oitava versão do método de IA desenvolvido pela Ultralytics, destaca-se pela sua aplicabilidade em projetos que exigem reconhecimento de imagem em tempo real. Disponibilizado gratuitamente, o método YOLOv8 oferece uma solução prática para a implementação de funcionalidades avançadas de IA em sistemas de controle de estoque. Seu sucesso recente deve-se, em grande parte, à sua capacidade de processar imagens rapidamente e com alta precisão, além de sua habilidade em contabilizar os itens identificados na imagem. Essas características são fundamentais para a modernização e otimização da gestão de estoques em ambientes dinâmicos e exigentes (ALVES, 2020).

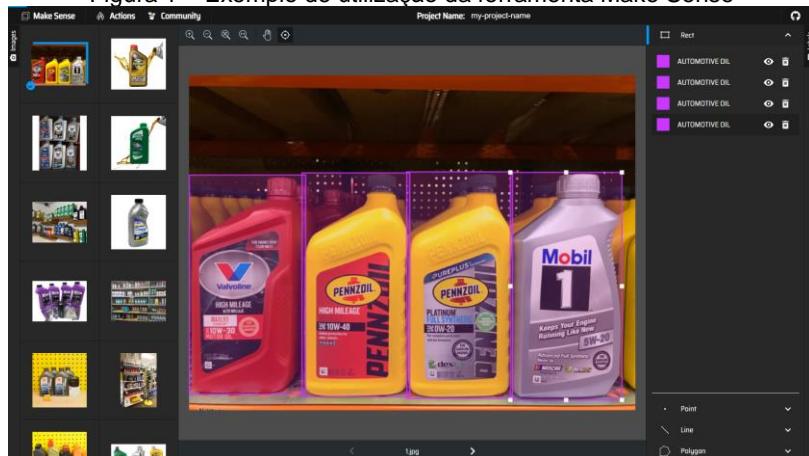
Metodologia

Conforme Goodfellow, Bengio e Courville (2016, p.801) Para o treinamento de redes neurais em visão computacional, é essencial adquirir muitas imagens para os processos de treinamento e validação. Nesse contexto, foram coletadas 43 imagens para treinamento e 19 imagens para validação a partir de diversas fontes na internet. Essas imagens passaram por uma análise, considerando aspectos como qualidade, tamanho e disposição dos objetos em relação à imagem final de inferência. Essa etapa visa garantir que as imagens sejam adequadas para um treinamento eficaz do modelo e para a validação dos resultados obtidos.

Para o desenvolvimento da programação, foi utilizada a linguagem Python, versão 3.10.11. Além disso, foi empregada a IDE Visual Studio Code para uma melhor organização do código e visualização do desenvolvimento.

Após a obtenção das imagens, é necessário realizar a indicação dos objetos a serem treinados, utilizando um arquivo de texto para cada imagem. Para isso, empregou-se a ferramenta online gratuita disponível em <https://www.makesense.ai/>. Essa ferramenta permite, de forma simplificada, marcar os objetos em cada imagem, indicando suas localizações (RAYAMAJHI, 2023). Esse processo de marcação é realizado em todas as imagens do conjunto de treinamento e validação, garantindo que o modelo possa aprender com todas as anotações. Abaixo está um exemplo de como essa orientação é realizada pela plataforma citada.

Figura 1 – Exemplo de utilização da ferramenta Make Sense



Fonte: Os autores

Após feita o apontamento de todos os objetos desejados em todas as imagens de validação e treinamento, serão gerados arquivos contendo a localização dos objetos em cada imagem, que serão utilizados pelo YOLOv8 para aprender a localização do objeto na imagem.

Em seguida, é necessário criar o programa principal na linguagem Python, conforme o passo a passo descrito na documentação da ferramenta. Este programa será responsável por realizar a chamada da ferramenta YOLO com os parâmetros especificados.

Tabela 1 – Parâmetros de aprendizagem da IA

Modelo	Qtd. Imagens	Épocas	Paciência	Conf. Mínima
YOLOv8m	43	200	100	0.1

Fonte: Os autores

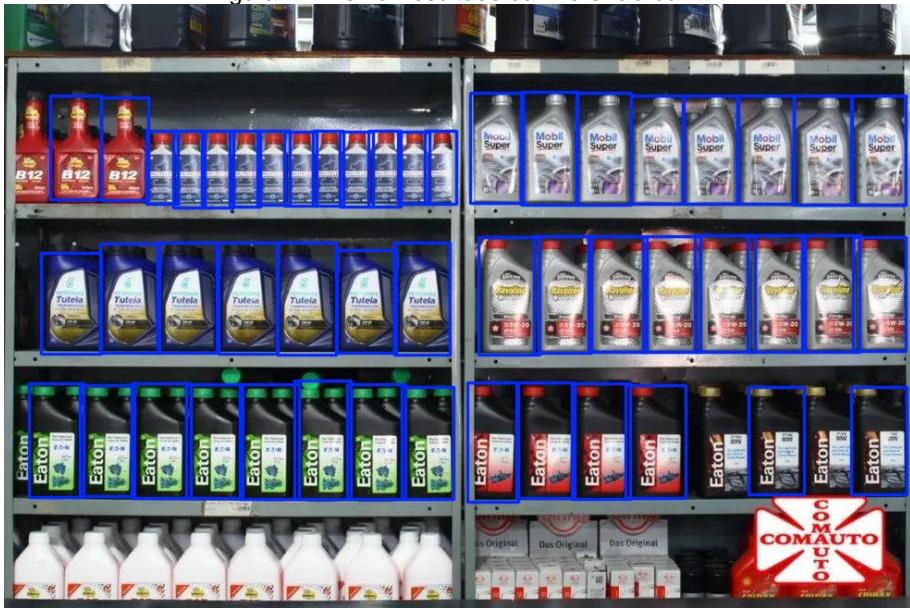
Os parâmetros apresentados na Tabela 1 correspondem a configurações que influenciam diretamente o processo de treinamento do modelo de IA, sendo eles:

- Modelo (YOLOv8m):** Indica o tipo de modelo de detecção de objetos utilizado. O YOLOv8m é uma variante do algoritmo que oferece um equilíbrio entre tamanho e desempenho, sendo uma versão intermediária da família YOLO.
- Qtd. Imagens (43):** Refere-se ao número de imagens usadas para treinar o modelo. Uma quantidade maior de imagens pode melhorar a capacidade de generalização do modelo, resultando em uma maior precisão nas detecções.
- Épocas (200):** Representa o número de vezes que o modelo passa por todo o conjunto de dados durante o treinamento. Um número maior de épocas pode contribuir para um melhor aprendizado do modelo, desde que controlado para evitar o sobre ajuste.
- Paciência (100):** Define quantas épocas o treinamento pode continuar sem melhoria significativa antes de ser interrompido, evitando assim o sobre ajuste e economizando recursos computacionais.
- Conf. Mínima (0.1):** Este é o limiar mínimo de confiança para considerar uma detecção como válida. Apenas detecções com confiança acima de 10% são mantidas, o que ajuda a filtrar previsões menos confiáveis e potencialmente reduzir falsos positivos.

Após essa etapa, deve-se executar o programa e aguardar a conclusão do treinamento para a obtenção dos resultados.

Resultados

Figura 2 – Melhor resultado da inferência da IA



Fonte: Os autores

Tabela 2 – Resultados da validação do treinamento

Imagens	Instâncias	Box Precision	Recall	mAP50	mAP50-95
19	221	0.803	0.679	0.793	0.589

Fonte: Os autores

O modelo apresentou resultados satisfatórios, com boa precisão e capacidade de identificar e localizar objetos nas imagens, conforme demonstrado na Figura 2 e nos dados da Tabela 2. O modelo identificou 50 dos 53 objetos previamente definidos, descartando aqueles que estavam sobrepostos, parcialmente visíveis na imagem, fora do escopo de treinamento, ou os galões. A tabela apresenta os resultados da validação do modelo de IA para detecção de objetos em 19 imagens, contendo 221 instâncias. A Box Precision (precisão da caixa) atingiu 0,803 (80,3%), indicando uma alta taxa de

acertos nas previsões. O Recall foi de 0,679 (67,9%), demonstrando que o modelo identificou 67,9% dos objetos presentes.

O mAP50 (*mean Average Precision*, Precisão Média Global com Interseção sobre União de 50% em português) atingiu 0,793 (79,3%), refletindo um bom desempenho na detecção de objetos, considerando uma sobreposição mínima de 50% entre as previsões do modelo e as localizações reais dos objetos. O termo IoU (Intersection over Union ou Interseção sobre União) refere-se à medida que avalia o quanto as caixas delimitadoras previstas pelo modelo coincidem com as caixas reais dos objetos.

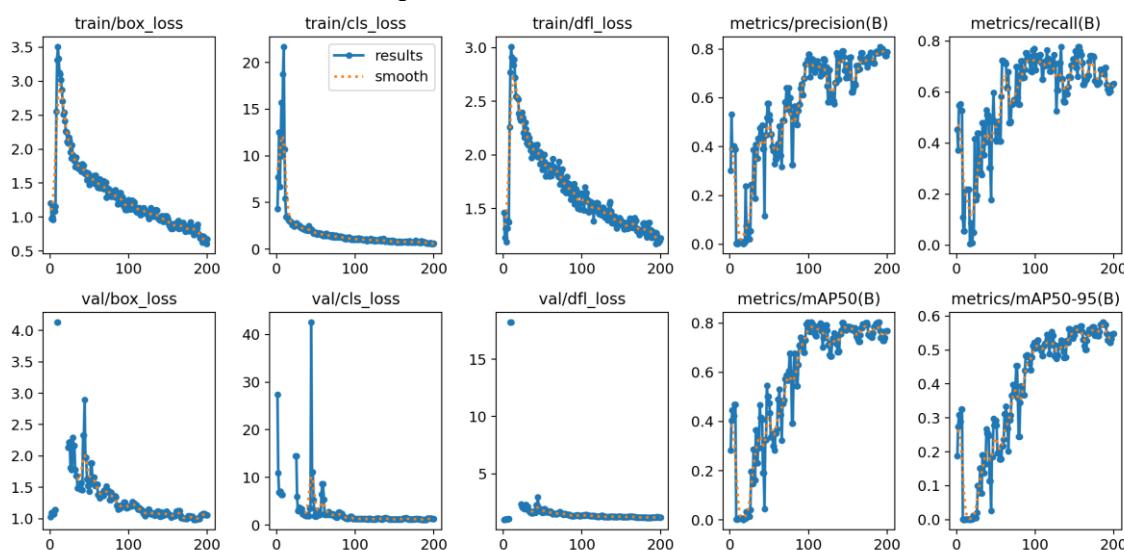
Por outro lado, o mAP50-95 (Precisão Média Global com Interseção sobre União variando de 50% a 95%) foi de 0,589 (58,9%), indicando uma precisão razoável em diferentes níveis de sobreposição, variando de 50% a 95%. A menor precisão observada no mAP50-95 pode ser atribuída à disposição aleatória dos objetos em cada imagem, o que dificultou o desempenho do modelo em prever corretamente as caixas delimitadoras em limiares de sobreposição mais rigorosos.

No entanto, como evidenciado anteriormente, houve uma dificuldade em detectar alguns litros de óleo automotivo. Observou-se que a quantidade limitada de imagens, a qualidade das imagens e a falta de exemplos representativos do resultado esperado resultaram em desvios na aprendizagem do modelo. Esses fatores impactaram a performance do modelo, ressaltando a importância de uma base de dados mais robusta e diversificada para aprimorar a acurácia dos resultados.

Os testes realizados e o treinamento do modelo foram conduzidos exclusivamente em imagens estáticas previamente selecionadas. Não foi possível validar o desempenho em um ambiente real, com uma câmera capturando a prateleira em tempo real, devido à limitação de tempo disponível.

Discussão

Figura 3 – Resultados do treinamento



Fonte: Os autores

O treinamento do modelo para o controle de estoque envolveu ajustes significativos nos parâmetros de treinamento, incluindo a quantidade de épocas, a confiabilidade mínima e a confiabilidade nas imagens finais. Apesar desses ajustes, o aumento na precisão foi observado somente após 100 épocas de treinamento, e a precisão estabilizou após 150 épocas conforme visto na Figura 3. Essa tendência indica que, embora o aumento das épocas tenha melhorado a precisão, o modelo atingiu um ponto de saturação, onde maiores números de épocas não resultaram em melhorias adicionais significativas.

Além disso, a eficácia do modelo também foi influenciada pela quantidade de imagens utilizadas. Inicialmente, nos testes iniciais que foram com apenas 25 imagens, o modelo demonstrou uma precisão limitada, que começou a melhorar significativamente somente após o aumento do número de imagens para treinamento para 43 e das imagens de validação para 19. Isso sugere que a quantidade de imagens tem um impacto crucial na capacidade do modelo de aprender e generalizar padrões de forma

eficaz. A melhoria na confiabilidade e na precisão das previsões foi notável após a inclusão de um número maior de imagens representativas, sublinhando a importância de uma base de dados mais robusta para o treinamento da IA. Um resultado dos testes iniciais pode ser visto na Figura 5.

Figura 5 – Resultado obtido com 30 imagens de treinamento.



Fonte: Os autores

A análise dos resultados revela que, para alcançar um desempenho ideal, é necessário um equilíbrio entre a quantidade de dados e o número de épocas de treinamento. Com um número insuficiente de imagens, o modelo pode não aprender padrões suficientes para fornecer previsões confiáveis. No entanto, uma vez que um número adequado de imagens é atingido, o treinamento adicional pode levar a uma estabilização da precisão, sugerindo que há um ponto de rendimento onde o modelo atinge sua capacidade máxima de aprendizado com os dados disponíveis. Esses achados ressaltam a importância de otimizar tanto os parâmetros de treinamento quanto a qualidade e quantidade dos dados para maximizar o desempenho da IA no controle de estoque.

Considerando o tempo necessário para encontrar as imagens, organizar os dados e realizar inferências (cerca de 5 dias), além da fase de desenvolvimento, treinamento da IA e ajustes posteriores (2 dias), a aplicação do modelo para controle de estoque em tempo real se mostra consideravelmente mais eficiente e precisa do que o controle de estoque manual.

O controle de estoque manual exige que funcionários realizem contagens físicas diárias ou semanais dos itens em estoque, o que pode consumir várias horas dependendo do tamanho do inventário. Esse processo não só consome tempo, como também é propenso a erros, como contagens incorretas, registros inadequados e falta de atualização em tempo real. Além disso, os custos envolvidos incluem o tempo de trabalho dos funcionários, que pode representar um valor significativo, especialmente em grandes empresas (PEDROSO; FAVARETTO; SAMPAIO, 2011).

Quando comparado ao controle por RFID (Radio-Frequency Identification), a situação se torna mais complexa. O controle por RFID oferece uma solução automatizada para rastrear itens em tempo real, utilizando etiquetas e leitores de rádio frequência. Este método reduz a necessidade de intervenção humana e minimiza erros na contagem de estoque. Além disso, o RFID permite atualizações instantâneas do status do estoque, facilitando o monitoramento e a reposição automática dos itens (PRAZERES, 2015).

Ainda conforme Prazeres (2015) destaca, o RFID também apresenta algumas limitações. A implementação dessa tecnologia envolve custos iniciais elevados, como a aquisição de etiquetas, leitores e infraestrutura necessária para integrar o sistema. Em ambientes onde o controle de estoque é dinâmico e sujeito a mudanças frequentes, os custos de manutenção e atualização do sistema podem ser significativos. Além disso, a precisão do RFID pode ser afetada por interferências de sinal e limitações de alcance, especialmente em estoques grandes ou com objetos metálicos.

Conclusão

O uso da Inteligência Artificial (IA) no controle de estoque de prateleiras apresenta diversas vantagens em comparação com o controle tradicional realizado por humanos. A implementação de

sistemas baseados em IA oferece alta precisão e consistência na contagem e monitoramento de estoque, minimizando erros humanos e melhorando a acurácia dos dados. A automação proporcionada pela IA permite a execução eficiente de tarefas repetitivas, como a contagem de itens, liberando recursos humanos para se concentrarem em atividades mais estratégicas e de maior valor. Além disso, a IA permite o monitoramento em tempo real por meio de tecnologias como visão computacional e sensores IoT (Internet das Coisas), possibilitando alertas automáticos sobre níveis baixos de estoque e irregularidades. A capacidade da IA de analisar grandes volumes de dados e identificar padrões e tendências também melhora a gestão de estoque e a previsão de demanda, contribuindo para a otimização dos níveis de inventário e a redução de rupturas de produtos.

Entretanto, a eficácia dos sistemas de IA está diretamente relacionada à qualidade e à quantidade de dados disponíveis. Quanto maior o número de imagens utilizadas para treinar o modelo, melhor será a capacidade da IA de identificar e classificar os itens com precisão. Além disso, a semelhança das imagens usadas no treinamento com a imagem final a ser analisada é crucial; imagens que são mais semelhantes ao cenário real garantem uma melhor adaptação do modelo e, consequentemente, uma maior precisão nos resultados. A dependência da IA da qualidade e quantidade dos dados disponíveis implica que dados incompletos ou imprecisos podem comprometer a eficácia do sistema (CHEN et al., 2017).

A adoção de sistemas de IA também enfrenta desafios como o custo inicial significativo de implementação e a complexidade tecnológica envolvida na configuração e manutenção dos sistemas, que pode exigir suporte técnico especializado. Apesar dessas limitações, a IA oferece um potencial considerável para aprimorar o controle de estoque, proporcionando uma alternativa eficiente e precisa ao método manual tradicional. Em resumo, a integração da IA no controle de estoque pode representar um avanço significativo na gestão de inventário, oferecendo benefícios em termos de precisão, eficiência e capacidade analítica.

Referências

- ABOAH, A. et al. **Real-time Multi-Class Helmet Violation Detection Using Few-Shot Data Sampling Technique and YOLOv8.** Pdf—Computer Vision Foundation - 7th AI City Challenge Workshop: [s.n.].
- ALVES, G. **Detecção De Objetos Com YOLO - Uma Abordagem Moderna.** Disponível em: <https://iaexpert.academy/2020/10/13/deteccao-de-objetos-com-yolo-uma-abordagem-moderna/?doing_wp_cron=1710369548.2119610309600830078125. Acesso em: 14 ago. 2024.
- CHEN, Z. et al. **Image Quality Assessment Guided Deep Neural Networks Training.** [s.l: s.n.]. Disponível em: <<https://arxiv.org/pdf/1708.03880.pdf>>. Acesso em: 14 ago. 2024.
- DANDARO, F.; MARTELLO, L. L. **Planejamento E Controle De Estoque Nas Organizações.** Pdf—Universidade Tecnológica Federal do Paraná - UTFPR: [s.n.].
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning.** 1. ed. <https://www.deeplearningbook.org/>: MIT Press, 2016. p. 801
- HUSSAIN, M. YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. **Machines**, v. 11, n. 7, p. 677, 1 jul. 2023.
- PRAZERES, Ricardo S. **RFID (Radio Frequency Identification - Identificação por rádio frequência): um estudo sobre a viabilidade em ambiente supermercadista,** 2015. Trabalho de conclusão de curso (Curso de Tecnologia em Segurança da Informação) - Faculdade de Tecnologia de Americana, Americana, 2015
- RAYAMAJHI, A. **Image Annotation Using Makesense.ai.** Disponível em: <<https://medium.com/@aleenarayamajhi13/image-annotation-using-makesense-ai-67468bd3598>>. Acesso em: 13 ago. 2024.

ULTRALYTICS. YOLOv8 **Tutorial.** Disponível em:
<<https://colab.research.google.com/github/ultralytics/ultralytics/blob/main/examples/tutorial.ipynb#scrollTo=nPZZeNrLCQG6>>. Acesso em: 12 ago. 2024.

WALTHER, A. **Amazon Utiliza IA Para Prever a Demanda E Otimizar Estoque.** Disponível em:
<<https://pt.linkedin.com/pulse/amazon-utiliza-ia-para-prever-demanda-e-otimizar-estoque-walther-igpzf>>. Acesso em: 10 ago. 2024.