

AUTOMAÇÃO DE LINHAS DE PRODUÇÃO USANDO MODELOS DE VISÃO COMPUTACIONAL

Ana Paula Sousa da Silva, Marcelo de Souza

INTRODUÇÃO

A automação dos processos de inspeção de produtos em busca de defeitos é essencial para a Indústria 4.0, pois diminui erros humanos e melhora a produtividade (Ren et al., 2022). Modelos de aprendizado profundo, como as redes neurais convolucionais (CNNs), têm apresentado bom desempenho na identificação de imperfeições em peças industriais. Apesar de eficazes, esses métodos precisam ser adaptados para cada área específica, uma vez que os dados e imagens são frequentemente escassos e heterogêneos (Tao et al., 2022).

DESENVOLVIMENTO

Este trabalho estuda a adoção e o desempenho de métodos de visão computacional baseados em CNNs para a inspeção de peças e identificação de defeitos de fabricação. Foram empregados dois conjuntos de dados públicos, disponibilizados na plataforma Kaggle: o “*Real-Life Industrial Dataset of Casting Product*” e o “*Few Shot Industrial Defect Detection*”. O primeiro deles inclui imagens de peças metálicas fundidas, com e sem defeitos, ao passo que o segundo exhibe diversas categorias de defeitos em componentes industriais variados, possibilitando testes em diferentes áreas. A Figura 1 apresenta dois exemplos de imagens do primeiro conjunto de dados. A primeira imagem (esquerda) corresponde a uma peça sem defeitos, enquanto a segunda (direita) mostra uma peça com uma falha na superfície. As imagens foram ajustadas para uma resolução de 224×224 pixels e separadas em grupos de treinamento, validação e teste.

Foram exploradas as redes VGG16, ResNet50 e MobileNetV2, todas usando pesos pré-treinados na ImageNet (RUSSAKOVSKY et al., 2015). Foi realizado o ajuste fino dessas redes para a tarefa de interesse, possibilitando o re-treinamento parcial das 30 camadas convolucionais finais do modelo que mostrou melhor desempenho em uma análise inicial. A estratégia implementada seguiu o modelo proposto por Cholett (2017), no qual as camadas superiores são adaptadas ao domínio da tarefa, enquanto as demais permanecem inalteradas. O treinamento empregou a augmentação de dados para melhorar a robustez dos modelos, usando variações de rotação, zoom e inversão horizontal. Na etapa de ajuste fino, foi adotada a função de perda de entropia cruzada categórica e o otimizador Adam com uma taxa de aprendizado de 0,0001.

RESULTADOS

O MobileNetV2 se destacou entre os modelos estudados, atingindo uma acurácia de 96,1% no primeiro conjunto de dados e valores acima de 60% em várias categorias do segundo conjunto de dados. A Figura 2 mostra os valores de acurácia desse modelo para ambos os conjuntos de dados, divididos entre os diferentes tipos de material ou

produto. Observa-se um maior desempenho do modelo para produtos de madeira, azulejos e grades, ao passo que o modelo tem dificuldades na inspeção de trilhos de trem e azulejos magnéticos. A área sob a curva ROC média foi superior a 0,95, o que indica boa capacidade de discriminação. Os modelos VGG16 e ResNet50 exibiram desempenho comparável, contudo com um custo computacional mais elevado. A análise confirma a eficácia de redes leves em situações com dados limitados e diversas condições industriais, como indicado por Xian Tao et al. (2022) e Jiaqi Liu et al. (2023). No entanto, observou-se que a aplicação do ajuste fino com o segundo conjunto de dados apresentou resultados menos satisfatórios, com poucos casos em que a acurácia superou 90%.

CONSIDERAÇÕES FINAIS

A aplicação de modelos de visão computacional fundamentados em deep learning revelou-se promissora para a automação de inspeções visuais em linhas de produção, resultando em maior eficácia e confiabilidade no controle de qualidade. Essa metodologia possibilita a diminuição de gastos com inspeções manuais e acelera a identificação de falhas. Como etapas futuras, planeja-se testar o modelo em outros conjuntos de dados industriais e investigar métodos de segmentação de defeitos, com o objetivo de aplicações ainda mais precisas, além de realizar um tratamento de dados mais sofisticado.

Palavras-chave: visão computacional; redes neurais convolucionais; detecção de falhas; automação industrial; aprendizado profundo.

ILUSTRAÇÕES



Figura 1. Exemplos de imagens usadas no estudo, incluindo uma peça sem defeitos (esquerda) e uma peça com falha na superfície (direita).




Figura 2. Acurácia do modelo MobileNetV2 nas diferentes categorias de produtos.

REFERÊNCIAS BIBLIOGRÁFICAS

CHOLETT, François. *Deep Learning with Python*. Manning Publications, novembre de 2017. ISBN 978-1617294433.

LIU, Jiaqi et al. *Deep industrial image anomaly detection: A survey*. Machine Intelligence Research, v. 21, n. 1, p. 104-135, 2024.

REN, Z. et al. State of the Art in Defect Detection Based on Machine Vision. *International Journal of Precision Engineering and Manufacturing-Green Technology*, v. 9, p. 661–691, 2022. Disponível em: <https://doi.org/10.1007/s40684-021-00343-6>. Acesso em: 20 jul. 2025.

RUSSAKOVSKY, Olga et al. *ImageNet Large Scale Visual Recognition Challenge*. 2015. Disponível em: <https://doi.org/10.48550/arXiv.1409.0575>. Acesso em: 20 jul. 2025.

TAO, Xian et al. *Deep learning for unsupervised anomaly localization in industrial images: A survey*. *IEEE Transactions on Instrumentation and Measurement*, v. 71, p. 1-21, 2022.

DADOS CADASTRAIS

BOLSISTA: Ana Paula Sousa da Silva

MODALIDADE DE BOLSA: PIVIC – VOLUNTÁRIO

VIGÊNCIA: 04/2025 a 08/2025 – Total: 5 meses

ORIENTADOR(A): Marcelo de Souza

CENTRO DE ENSINO: CEAVI

DEPARTAMENTO: Departamento de Engenharia De Software

ÁREAS DE CONHECIMENTO: Ciências Exatas e da Terra / Ciência da Computação

TÍTULO DO PROJETO DE PESQUISA: Projeto Automático de Algoritmos

Nº PROTOCOLO DO PROJETO DE PESQUISA: NPP4054-2022