

PROPOSTA DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE DEFEITOS EM PEÇAS MANUFATURADAS ADITIVAMENTE

LUCAS MACEDO DA SILVA¹, SYMONE GOMES SOARES ALCALÁ², TALLES MARCELO G. DE A. BARBOSA³

¹Mestrando Engenharia de Produção, UFG, Aparecida de Goiânia-GO, luckasmacedo2@gmail.com;

²Dr.^a Engenharia Elétrica e da Computação, UFG, Aparecida de Goiânia-GO, symone@ufg.br

³Dr. Engenharia Elétrica, PUC, Goiânia-GO, talles.ucg@gmail.com

Apresentado no
Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC
4 a 6 de outubro de 2022

RESUMO: A manufatura aditiva vem ganhando cada vez mais espaço na indústria devido à possibilidade de criar produtos customizados sob medida. O processo de manufatura aditiva, no entanto, é propenso a falhas e pode levar a peças defeituosas. A inspeção que pode ser realizada por um ser humano é um processo lento, cansativo e suspenso; mas que pode ser realizada e otimizada por um computador. Os métodos de detecção de objetos podem ser aplicados para realizar a detecção automática de defeitos. Desta forma, este trabalho apresenta uma proposta de processo para detecção de objetos defeituosos em imagens utilizando duas redes neurais, cada uma especializada em uma tarefa. Para isso, foi utilizado o algoritmo FASTER RCNN para detectar os objetos, isto é, identificar os objetos nas imagens. Então, esses objetos são a entrada para uma rede CNN responsável por definir se o objeto está com defeito ou não. O modelo completo conseguiu realizar as duas tarefas, detectando os objetos com mAP de 0,65 e definindo se eles eram defeituosos com 90% de acurácia.

PALAVRAS-CHAVE: manufatura aditiva, processo, detecção de defeitos, peças, inteligência artificial.

PROPOSAL OF ARTIFICIAL INTELLIGENCE MODELS FOR DETECTION OF DEFECTS IN ADDITIVELY MANUFACTURED PARTS

ABSTRACT: Additive manufacturing has been gaining more space in the industry due to the possibility of creating custom-made products. However, the additive manufacturing process is prone to failure and can lead to defective parts. The inspection that can be performed by a human is slow, tiring, and suspended process; but it can be performed and optimized by a computer. Object detection methods can be applied to perform automatic defect detection. In this way, this work presents an process proposal for the detection of defect objects in images using two neural networks, each one specialized in a task. For this, the FASTER RCNN algorithm was used to detect the objects, that is, to identify the objects in the images. So, these objects are the input to a CNN network responsible for defining whether the object is faulty or not. The complete model was able to accomplish both tasks, detecting objects with mAP of 0.65 and defining if they were defective with 90% accuracy.

KEYWORDS: additive manufacturing, architecture, defect detection, parts, artificial intelligence.

INTRODUÇÃO

A Manufatura Aditiva (MA) trata-se de uma tecnologia para a construção de objetos a partir da suposição de camadas. O processo consiste em construir um objeto a partir de um modelo previamente moldado em sistemas de computação assistida. Esse modelo é levado para uma impressora 3D que gera o objeto camada a camada. Entretanto, o processo sofre com defeitos causados pelo seu processamento, como, por exemplo, porosidade, trincas e distorções (WANG et al., 2020). A detecção desses defeitos costuma ser realizada manualmente, em que um ser humano inspeciona visualmente as peças uma a uma. Esse método, contudo, consome muito tempo, além de apresentar alta taxa de erro. Contudo, é possível empregar técnicas computacionais em conjunto com algoritmos de Inteligência Artificial (IA) para realizar a detecção de objetos defeituosos com maior

taxa de sucesso e eficiência, e menos custos (YE et al., 2021). O sistema para a detecção de objetos defeituosos pode ser construído utilizando uma plataforma composta por uma câmera, uma unidade de processamento e um computador, por exemplo.

O trabalho de Kim *et al.* (2012) apresenta um método para realizar a detecção de produtos manufaturados defeituosos a partir de imagens. Os autores empregaram um perceptron multicamadas para realizar a detecção dos objetos que estavam presentes em uma esteira. Como muitos objetos são tratados, foi utilizado um robô para realizar a separação dos objetos que são a entrada para o detector de objetos. Foi empregado um conjunto de dados (do inglês *dataset*) desenvolvido pelos autores e a acurácia obtida pelo modelo foi de 99,8%. O sistema conseguiu obter bons resultados com um modelo simples de rede neural, contudo, ele necessita de um equipamento especial que é o robô, o que pode aumentar o custo de desenvolvimento e manutenção além da acessibilidade do sistema.

Por outro lado, Zhou *et al.* (2018) apresentam um método baseado no aprendizado por transferência para a detecção de defeitos em conjuntos de dados com poucas amostras. O conjunto de dados utilizado foi desenvolvido pelos autores. Foram utilizadas duas redes neurais para formar um *ensemble*. Foram realizados testes com duas arquiteturas de redes diferentes, Inception e MobileNet, sendo que a precisão de classificação delas no conjunto de teste é de 95,6% e 93,9%, respectivamente. O trabalho empregou a aprendizagem por transferência em conjunto com o aumento de dados para realizar a detecção. Essa abordagem reduz o tempo gasto no treino da rede, pois permite aproveitar o aprendizado anterior da rede em uma nova tarefa. O uso das redes em conjunto melhorou o desempenho e a precisão na classificação, contudo, os autores focaram em apenas um dos problemas, a detecção de defeitos.

Desta forma, este trabalho apresenta um processo para a detecção de defeitos em peças produzidas por MA com duas redes neurais, cada uma com uma tarefa distinta, sendo que uma rede detecta o objeto e a outra detecta o defeito. A primeira rede utiliza um algoritmo FASTER RCNN (do inglês – FASTER *Region Based Convolutional Neural Networks*). Para a tarefa de detecção de defeitos, foi empregada uma rede CNN (do inglês - *Convolutional Neural Networks*). A primeira rede detecta o objeto e, então a partir da localização dele na imagem, o mesmo é cortado da imagem e redimensionado para ser a entrada para a segunda rede que define se o objeto é defeituoso ou não. Essa abordagem permite melhorar o custo computacional, pois as redes são treinadas para atividades específicas. O modelo completo, composto pela junção das duas redes, conseguiu realizar as duas tarefas, detectando os objetos com mAP de 0,65 e definindo se eles eram defeituosos com 90% de acurácia. Os resultados mostraram que a proposta teve bons resultados mesmo com as redes treinadas com poucas imagens.

MATERIAIS E MÉTODOS

O desenvolvimento dos modelos foi realizado na plataforma Google Colab que permite um ambiente homogêneo e configurável, além de contar com uma unidade de processamento gráfico. A linguagem de programação utilizada foi o Python em conjunto com a biblioteca *Tensorflow Object Detection API* (do inglês – *Application Programming Interface*). A metodologia utilizada para o desenvolvimento do modelo consistiu em realizar o *download* do modelo, configurar seus parâmetros, treiná-lo, avaliá-lo e testá-lo. Após esse processo os modelos foram salvos em disco para serem utilizados futuramente sem a necessidade de realizar o treino novamente.

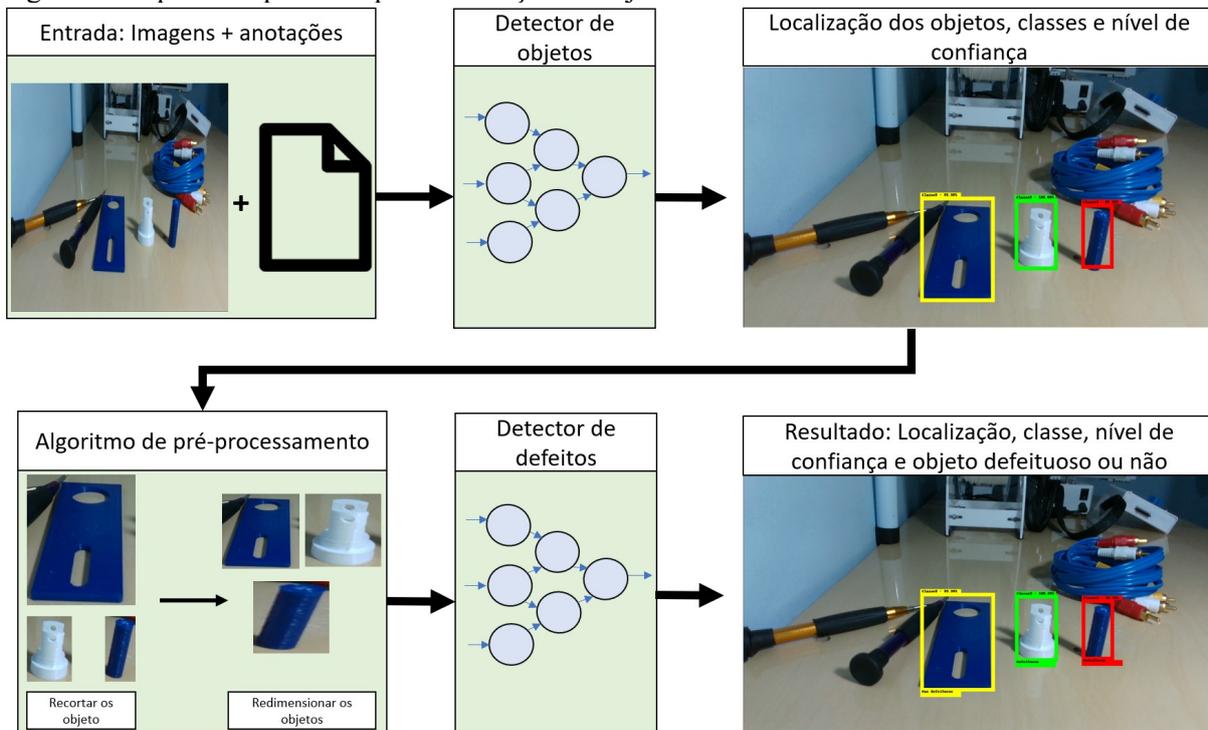
O conjunto de dados empregado neste trabalho foi levantado por Souza e Alcalá (2022). Ele é formado por mais de 1.000 imagens de objetos manufaturados em diferentes posições, condições de iluminações e cenários distintos. Os objetos são dispostos nas imagens em diferentes posições e distâncias da câmera, cada imagem contém de 1 a 7 objetos. Cada objeto é definido em uma classe que o rotula. Isto é, define a categoria ao qual o objeto pertence, por exemplo, se o objeto é um botão então sua classe é botão. Além disso, as imagens estão anotadas com informações referentes à localização dos objetos. Para este trabalho, contudo, o conjunto de dados foi subamostrado, pois alguns dos arquivos que continham as informações dos objetos presentes na imagem estavam incorretos, fazendo com que a localização do objeto anotado não correspondesse com a localização verdadeira na imagem, essas imagens foram retiradas do conjunto de dados. A subamostragem foi então realizada de forma aleatória a partir de um *script* desenvolvido em Python que acessa os diretórios e então amostra aleatoriamente as imagens e as reparte em conjuntos de treino e teste dos modelos; sendo separadas

159 imagens para serem utilizadas para a rede que detecta de defeitos e 128 imagens para serem utilizadas pela rede de detecção de defeitos. Além disso, também foi desenvolvido um *script* responsável por converter as anotações do *dataset* para qualquer outro tipo de anotação, pois diferentes modelos recebem diferentes anotações dos dados.

A Figura 1 a seguir apresenta o processo proposto. A entrada dos dados é composta pela imagem e a anotação dos dados. A anotação é necessária para realizar o treino do detector de objetos, em testes com o modelo em produção a informação das anotações não será necessária. Esses dados são então a entrada para o modelo detector de objetos, sendo que ele é responsável por localizar o objeto na imagem e dizer qual a classe esse objeto pertence, bem como o nível de confiança dessa classificação. A saída do detector de objetos é então processada, onde cada objeto é recortado da imagem e após redimensionado para 128 x 128 pixels. Esse processamento é necessário, pois a CNN tem entrada limitada. Esses objetos recortados são a entrada para o detector de defeitos. Ele é responsável por dizer se aquele objeto é defeituoso ou não.

Com isso, ao final do processamento têm-se as informações referentes a localização do objeto, a caixa delimitadora que contorna o objeto, a classe ao qual ele pertence, a confiabilidade da classificação e se o mesmo possui ou não defeitos. A FASTER RCNN foi treinada por transferência de aprendizagem durante 10.000 épocas, sendo que o treino durou cerca de 2 horas. O modelo base utilizado foi a FASTER RCNN Resnet 50 previamente treinado com o conjunto de dados *Microsoft Common Objects in COntext* (MS COCO). Essa abordagem permite utilizar um modelo mais robusto sem a necessidade de perder muito tempo com a etapa de treino que costuma ser a mais demorada. Do conjunto de dados utilizado neste trabalho, foram utilizadas 101 imagens para treino e 31 imagens para teste. O modelo utilizado para a classificação se o objeto está defeituoso ou não foi uma CNN, a rede foi treinada com 298 imagens e testada com 59 imagens. A rede foi treinada por 100 épocas, a duração do treinamento foi de aproximadamente 2 horas. Para avaliar a detecção dos objetos, foi empregada a métrica mAP que compara a caixa delimitadora predita pelo modelo e a caixa delimitadora real, sendo que quanto mais próxima do valor 1 mais preciso é o modelo. Por outro lado, a avaliação do detector de defeitos foi realizada a partir da acurácia que diz a proximidade entre o valor predito pelo modelo e o valor real.

Figura 1. Proposta do processo para a detecção de objetos e defeitos



Fonte: Elaborado pelos autores

RESULTADOS E DISCUSSÃO

O modelo detector de objetos conseguiu obter mAP de 0,65, além de conseguir encontrar objetos pequenos presentes na imagem e gerar corretamente as caixas delimitadoras em volta do objeto. Optou-se por utilizar o modelo FASTER RCNN. Entretanto, no conjunto de dados existem objetos cilíndricos que dependendo da posição da imagem faz com que eles fiquem distorcidos e o modelo apresenta dificuldade em realizar a tarefa, exemplo de tal objeto é aquele circulado em verde na Figura 2B. Este problema pode ser resolvido aplicando pré-processamento na imagem de entrada exaltando características específicas de cada objeto, reduzindo assim a quantidade de características que a rede tem que aprender.

Em relação ao detector de defeitos foi utilizada uma CNN que foi treinada com poucas épocas (100 épocas), mas conseguiu uma acurácia de 90%. Isso se deve ao fato de a mesma se preocupar apenas em detectar o defeito, assim a imagem de entrada tem suas dimensões reduzidas e não contém informações desnecessárias como, por exemplo, todo o fundo da imagem. Desta forma, a rede se preocupa apenas em aprender características específicas dos objetos, retirando todo o custo necessário para processar a imagem completa. A rede errou apenas 6 (cerca de 10%) imagens do conjunto de teste. Mostrando, portanto, que o modelo conseguiu obter um bom resultado mesmo quando treinado com poucas etapas e um conjunto de dados limitado.

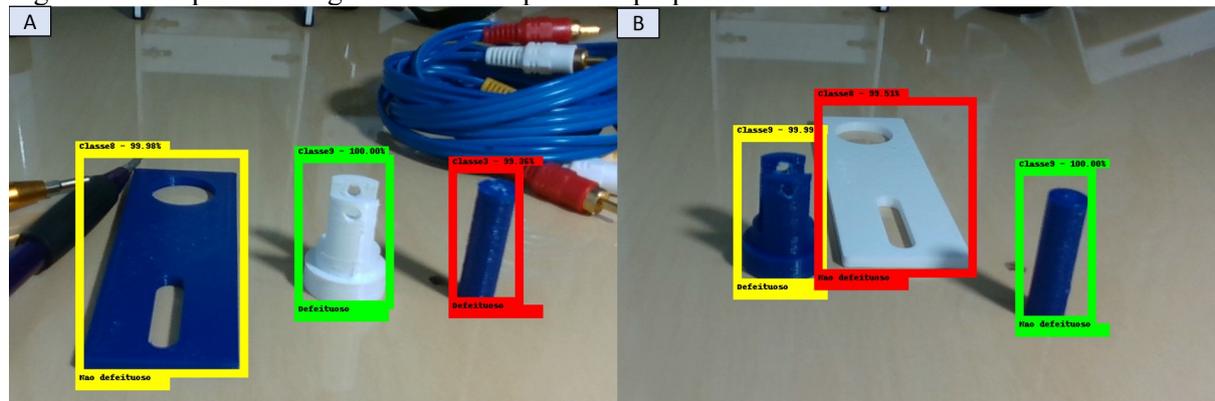
Tabela 1. Matriz de confusão para a rede CNN na detecção de defeitos

Classe	Defeituoso	Não defeituoso
Defeituoso	16	2
Não defeituoso	4	37

Fonte: Elaborado pelos autores

O modelo completo é formado pela união das duas redes conforme apresentado na Figura 1. A junção das duas consiste em detectar a localização do objeto utilizando a rede que detecta os objetos e após recortar a imagem e dar como entrada para o detector de defeitos. Desta forma, ao final do processo é possível obter informações quanto à localização do objeto, à caixa delimitadora em volta do objeto, à classe ao qual o objeto pertence, ao nível de certeza de que o objeto pertence à classe e à definição se o objeto é defeituoso ou não. A Figura 2 a seguir apresenta o teste do modelo completo em duas imagens do conjunto de dados. Nas imagens é possível verificar reflexos no fundo, além de outros objetos, mas o modelo conseguiu classificar e detectar corretamente os objetos ao qual ela foi treinada.

Figura 2. Exemplos de imagens de teste no processo proposto



Fonte: Elaborado pelos autores

A cooperação das duas redes facilita o processo, pois cada uma fica com uma tarefa bem definida. Além disso, a detecção de defeitos é realizada apenas em objetos encontrados pela modelo detector de objetos, isso evita que um objeto do cenário que não faz parte do escopo seja classificado como defeituoso, o que pode dificultar as análises e consequentemente gerar falsos positivos. Com

isso, é possível especializar o conhecimento, de forma que a rede de detecção de defeitos precisa apenas aprender a encontrar defeitos nos objetos, pois a rede de detecção de objetos já encontra o objeto e o disponibiliza como entrada para a outra rede. Além disso, na literatura costuma-se tratar os esses dois problemas isoladamente. A separação das tarefas em duas redes diferentes permite que ambas sejam treinadas para coisas distintas e específicas.

CONCLUSÃO

O presente trabalho propôs um processo para a detecção de objetos e defeitos separando as duas tarefas em duas redes distintas, onde cada uma tem uma responsabilidade específica. Isso melhora o custo computacional, além de permitir realizar treinos com modelos menos complexos. Na literatura, os trabalhos geralmente empregam um único modelo para realizar a tarefa, isso faz com que o consumo computacional do modelo seja muito alto. Além disso, o mesmo se preocupa com outras informações da imagem, o que pode fazer com que o modelo aprenda características desnecessárias para realizar a tarefa. Outra abordagem também encontrada é a de realizar apenas uma das tarefas a partir de um único modelo especializado.

O modelo desenvolvido é capaz então de detectar os objetos, apresentando sua localização na imagem, a caixa delimitadora que contorna o objeto, a classe ao qual o objeto pertence, o nível de confiabilidade que o modelo tem daquela classificação, além da informação se o objeto é defeituoso ou não. A FASTER RCNN conseguiu detectar os objetos com uma mAP de 0,65, enquanto a CNN detectou os objetos defeituosos com uma acurácia de 90%, mesmo ambas sendo treinadas com conjuntos de dados limitados e sem nenhum tipo de pré-processamento nos dados de entrada.

Os modelos foram treinados com apenas uma parte do conjunto de dados, desta forma, o treino das redes com o conjunto completo espera-se que a avaliação dos modelos melhore. Além disso, o conjunto de dados contém anotações referentes a localização do defeito no objeto, assim, pode ser treinado um modelo que seja responsável por contornar o defeito no objeto, facilitando então as análises do objeto defeituoso e ajudando a diminuir a ocorrência dos defeitos. Esta proposta de processo não se limita apenas a objetos manufaturados, também podendo ser aplicada na construção de sistemas vestíveis que possam auxiliar pessoas com deficiência visual a encontrarem produtos em um supermercado entre outros.

AGRADECIMENTOS

Este trabalho foi realizado com o apoio do projeto CNPq (Processo nº 428142/2018-4, Chamada MCTIC/CNPq Nº 28/2018 – Universal 2018), essencial para realização dessa pesquisa.

REFERÊNCIAS

- KIM, K. *et al.* *Object recognition for cell manufacturing system*. 2012 9th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI), nov. 2012.
- SOUZA, Manuel Peradeles de Castro e; ALCALÁ, Symone Gomes Soares. DESENVOLVIMENTO DE ABORDAGENS COMPUTACIONAIS PARA A DETECÇÃO DE DEFEITOS EM PEÇAS PRODUZIDAS EM PROCESSOS DE MANUFATURA ADITIVA. 2022. 86 f. Tese (Mestrado) - Curso de Engenharia de Produção, Universidade Federal de Goiás, Aparecida de Goiânia, 2022.
- YE, L. *et al.* *Application of deep learning in workpiece defect detection*. *Procedia Computer Science*, v. 183, p. 267–273, 2021.
- WANG, C. *et al.* *Machine learning in additive manufacturing: State-of-the-art and perspectives*. *Additive Manufacturing*, v. 36, p. 101538, dez. 2020.
- ZHOU, B. *et al.* *An Image-Based Approach for Defect Detection on Decorative Sheets*. *Neural Information Processing*, p. 659–670, 2018.