

# UMA REVISÃO SISTEMÁTICA SOBRE A DETECÇÃO DE OBJETOS DEFEITUOSOS PRODUZIDOS POR MANUFATURA ADITIVA

Lucas Macedo da Silva (Universidade Federal de Goiás)

[macedolucas@discente.ufg.br](mailto:macedolucas@discente.ufg.br)

Symone Gomes Soares Alcalá (Universidade Federal de Goiás)

[symone@ufg.br](mailto:symone@ufg.br)



*A Manufatura Aditiva (MA) é uma tecnologia disruptiva que permite a criação de objetos personalizados sob demanda a um custo reduzido. Essa tecnologia de fabricação de objetos é baseada na impressão camada a camada utilizando uma impressora 3D. No entanto, devido ao processo de fabricação aditiva, os objetos produzidos estão sujeitos a defeitos, que devem ser identificados antes de serem entregues ao usuário final. A inspeção visual realizada por um ser humano é comum para detectar defeitos, mas é um processo lento, desgastante e propenso a falhas. Sendo assim, o uso de técnicas de aprendizagem profunda, um ramo do aprendizado de máquina, pode possibilitar uma inspeção automatizada e eficiente de defeitos em objetos produzidos por MA. Para tal fim, é necessário selecionar, treinar e testar um modelo de aprendizado de máquina, além de definir o conjunto de dados que será utilizado pelo modelo. Na literatura, diferentes autores abordam a detecção de defeitos em objetos fabricados por manufatura aditiva de forma distinta. O presente estudo, portanto, apresenta uma revisão sistemática da literatura sobre modelos de aprendizagem profunda aplicados na detecção de objetos defeituosos produzidos por manufatura aditiva. Entretanto, na literatura, há poucos estudos que realizam uma revisão sobre esse assunto. Assim, para abordar essa lacuna, foi realizada uma revisão de literatura dividida em três etapas, cada uma refinando e sistematizando os estudos presentes. Ao final, esses estudos são comparados e discutidos, e os trabalhos mais relevantes são descritos em forma de tabela de trabalhos relacionados. Os resultados obtidos e sistematizados através da revisão do estado-da-arte demonstram o uso de modelos e conjuntos de dados personalizados como solução para os problemas propostos pelos autores. Adicionalmente, são discutidos cinco trabalhos de maior relevância e afinidade com o tema abordado nesta pesquisa.*

*Palavras-chave: detecção de objetos, detecção de defeitos, manufatura aditiva, modelos de aprendizagem profunda, revisão sistemática*

## 1. Introdução

A Manufatura Aditiva (MA), ou também conhecida como impressão 3D, trata-se de uma tecnologia disruptiva que possibilita a prototipação rápida e a criação de objetos personalizados. A MA é amplamente empregada em diversas áreas do conhecimento humano, como, construção civil, prototipagem e biomecânica (NGO et al., 2018). As principais vantagens da MA são: *prototipação rápida*, isto é, a criação e impressão de um objeto rapidamente utilizando os softwares CAD (PRAKASH; NANCHARAIH; RAO, 2018); *customização*, ou seja, a criação de objetos personalizados, produzindo pequenas quantidades de objetos específicos sob demanda (SITOTAW et al., 2020); *baixo custo*, isto é, redução de desperdícios e consequente economia de custos para a empresa (GONZALEZ-GUTIERREZ et al., 2018); *processo mais sustentável*, pois durante a impressão apenas o material necessário é utilizado, além da utilização de materiais biodegradáveis (VANDERPLOEG; LEE; MAMP, 2016); *produção just-in-time*, isto é, a criação de objetos sob demanda (FRAZIER, 2014); e *complexidade dimensional* em que diferentemente dos métodos tradicionais, consegue lidar com complexidade geométrica e materiais que não podem ser criados utilizando técnicas convencionais (GONZALEZ-GUTIERREZ et al., 2018).

Um objeto é manufaturado aditivamente a partir da sobreposição de camadas. Ele é primeiro modelado em um sistema de computação assistida (do inglês, *Computer Aided Design - CAD*) que descreve o objeto no formato reconhecido pela impressora 3D. Após, a impressora 3D recebe o objeto e a partir da sobreposição das camadas do material escolhido (exemplo, polímeros, cerâmicas ou metais) imprime o objeto. Depois de impresso o objeto é removido da impressora 3D, e então as camadas sobressalentes ou de apoio são removidas. Ao final, o objeto é inspecionado em busca de defeitos ou irregularidades na sua estrutura (NASIRI; KHOSRAVANI, 2021).

A inspeção dos objetos produzidos é uma etapa importante no processo de fabricação, pois garante a qualidade do produto e evita que produtos defeituosos cheguem ao usuário final (HUANG; PAN, 2015). Essa tarefa costuma ser realizada por um especialista humano que inspeciona visualmente as peças uma a uma. Isso é uma tarefa lenta, cansativa, pouco precisa e altamente suscetível a erros, além de requerer treinamento e tempo para o desenvolvimento das habilidades (CHEN; SU; CHEN, 2009). Contudo, é possível aplicar a inspeção automática, onde um modelo de aprendizado de máquina realiza a detecção de objetos defeituosos com rapidez e precisão a partir de imagens obtidas dos objetos.

Para isso, estes modelos devem realizar duas tarefas: a detecção do objeto na imagem e a

classificação do objeto como sendo defeituoso ou não. A primeira tarefa é denominada detecção de objetos e consiste em encontrar a localização do objeto na imagem e definir a ele uma classe associada ao tipo do objeto (WU; SAHOO; HOI, 2020). Por outro lado, definir se o objeto é defeituoso ou não defeituoso se trata de uma tarefa de classificação binária. A classificação binária é um problema que busca determinar entre duas classes mutuamente exclusivas a classe que a amostra pertence (ALPAYDIN, 2014). Na detecção de objetos defeituosos, as duas classes possíveis são: defeituoso ou não defeituoso.

Estes modelos necessitam de um conjunto de imagens (do inglês *dataset*) para serem treinados e avaliados. O conjunto deve ser previamente levantado que costuma ser realizado pelos seguintes passos: definição do problema, montagem do cenário, aquisição das imagens e anotação dos dados. A definição do problema consiste em delinear os componentes que a imagem deve possuir para caracterizar um cenário do problema. A aquisição das imagens consiste em obter fotos ou vídeos dos objetos no cenário montado em diferentes posições, condições de iluminação e distâncias. Por fim, a anotação dos dados onde as imagens são analisadas e os dados presentes são sistematizados, como a localização e a classe do objeto.

Dessa forma, é possível construir um sistema que realize a detecção automática de defeitos. Ele será formado por uma câmera que captura a imagem e uma unidade de processamento que recebe a imagem e a processa a partir de um modelo de aprendizagem profunda. A saída são informações referentes ao objeto detectado, dentre essas informações, a localização do objeto e se o objeto é defeituoso. O modelo por sua vez, deve ser primeiramente treinado com um conjunto de imagens que contém exemplos de objetos que o mesmo deverá detectar.

Contudo, na literatura são aplicados diferentes modelos para realizar a tarefa. Os autores geralmente melhoram um modelo para cenários específicos e, após testá-lo resumem as informações em um trabalho. Além disso, esses modelos são avaliados por diferentes métricas e são treinados com diferentes conjuntos de dados. Assim, não existe uma sistematização que defina quais são os modelos, métricas e conjuntos de dados mais utilizados na literatura.

Na literatura, os modelos de aprendizagem profunda para a detecção de objetos manufaturados são pouco explorados. Estes modelos empregam redes neurais profundas para aprender a representação dos dados de entradas, para então serem capazes de realizar tarefas, como, classificação, detecção e geração de dados (GOODFELLOW; BENGIO; COURVILLE, 2016). Eles são capazes de realizar a detecção após o treinamento com um conjunto de imagens (TABERNIK *et al.*, 2019). Assim, após o treino eles são capazes de encontrar os defeitos nos objetos de forma eficiente.

Sendo assim, o presente trabalho apresenta uma revisão de literatura referente a modelos de aprendizagem profunda aplicados na detecção de objetos defeituosos. O principal do foco do trabalho é a aplicação dos conceitos na detecção de objetos produzidos por manufatura aditiva, visto que na literatura este tema é pouco abordado. Para tanto, foi realizada uma revisão sistemática da literatura a fim de sumarizar as informações do estado da arte. A revisão foi baseada no processo proposto por Gil (2010). Como resultado, foram obtidas informações sumarizadas do estado da arte, além da análise e discussão de trabalhos relevantes inerentes ao tema.

## **2. Materiais e métodos**

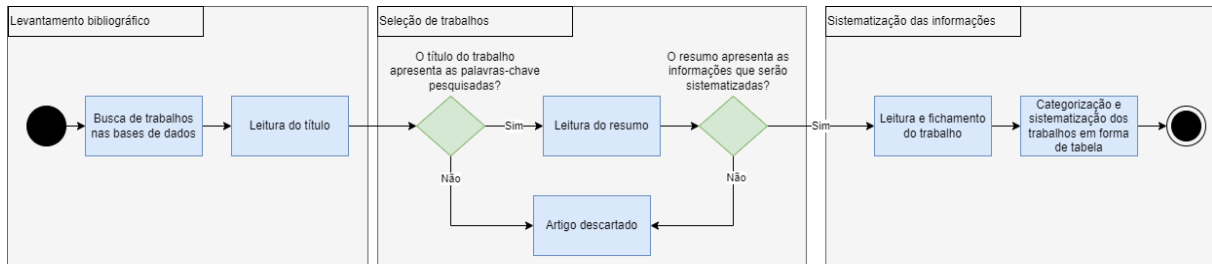
A revisão de literatura foi baseada em Gil (2010), para este autor este tipo de revisão consiste na sistematização das informações presentes em diferentes trabalhos e documentos. A primeira etapa consiste no levantamento dos trabalhos, seguida da leitura dos resumos dos trabalhos, leitura e fichamento do trabalho, e por fim, na sistematização do trabalho em forma de tabela. Dessa forma, a revisão de literatura do presente trabalho foi dividida em três etapas, sendo elas, o levantamento bibliográfico, a seleção de artigos e a sistematização dos trabalhos.

A etapa de levantamento consiste na busca por trabalhos nas bases de dados selecionadas. A etapa de seleção de trabalho busca definir se o trabalho está relacionado ao objeto de estudo e se ele deve ser lido e fichado. Por fim, na sistematização das informações, os trabalhos selecionados são lidos e fichados e após descritos em uma tabela que apresenta as informações levantadas. Na Figura 1, a seguir é apresentado o método aplicado para a realização da revisão. As próximas seções descrevem em detalhes cada etapa.

Ao final do processo serão respondidas as seguintes questões:

- I. Quais são os modelos de aprendizagem profunda mais utilizados na literatura para a detecção de objetos defeituosos e, em especial, para a detecção de objetos manufaturados aditivamente?
- II. Quais são os conjuntos de dados mais utilizados na literatura para o desenvolvimento de modelos de aprendizagem profunda?
- III. Quais são as métricas de desempenho dos modelos mais utilizadas?
- IV. Como os autores resolvem a tarefa de detecção de objetos?
- V. Como os autores resolvem a tarefa de detecção de defeitos em objetos?

Figura 1 – Método empregado para a revisão de literatura



Fonte: Autores

## 2.1. Levantamento bibliográfico

Esta etapa tem como objetivo buscar no estado-da-arte os conceitos e as definições para o prosseguimento da pesquisa, bem como, selecionar trabalhos relacionados para a construção de uma tabela comparativa. Dessa forma, para o levantamento bibliográfico foram levantados trabalhos nas bases de dados: *IEEE Xplore*, *Google Scholar*, *ACM Digital Library*, *Science Direct*, *Springer* e *Computer Vision Foundation*. As palavras-chaves utilizadas nas bases foram: “*Object detection*”, “*Object detection review*”, “*Models for object detection*”, “*Object recognition*”, “*Additive Manufacturing*”, “*Defect detection*”, “*Deep learning in additive Manufacturing*”, “*Additive manufacturing defects*” e “*Process for additive manufacturing*”.

O levantamento foi realizado no período de 30 de março de 2021 às 00:00 horas a 17 de abril de 2023 às 21:00 horas. Após a aplicação das palavras-chave nas bases de dados e a leitura dos títulos dos trabalhos, foram selecionados previamente 200 trabalhos, incluindo 195 artigos e 5 livros, que tratavam do assunto relacionado às palavras-chave pesquisadas.

## 2.2. Seleção de trabalhos

A seleção de trabalhos busca filtrar os trabalhos previamente selecionados, encontrando aqueles mais relacionados ao objeto de pesquisa. O primeiro critério de exclusão foi o título, caso o título não constasse o objeto de estudo o trabalho era excluído. Após, é realizada a leitura de todo o resumo (*abstract*) do trabalho, em que é respondida uma única questão: O resumo apresenta as informações que serão sistematizadas? Para responder essa pergunta é verificado se o trabalho cita o conjunto de dados, métricas, modelos, resolução do problema proposto e inovação, ou seja, responde às questões de pesquisa previamente definidas. Caso o trabalho apresente estes itens, o mesmo é selecionado para a próxima etapa. Além destes trabalhos, também são selecionados trabalhos que apresentem conceitos e definições pertinentes ao objeto de estudo e que sirvam de embasamento para o prosseguimento da pesquisa. Dos 200 trabalhos selecionados anteriormente, 36 deles foram selecionados nessa etapa.

### 2.3. Sistematização das informações

A última etapa da revisão consiste na leitura completa, fichamento do trabalho e sistematização dos trabalhos em forma de tabela. Primeiramente, o artigo foi lido destacando as informações importantes presentes no trabalho. Após, foi realizada novamente a leitura escrevendo as informações em um ponto separado, além de anotar os dados para o preenchimento da tabela. Os dados eram: *referência* (isto é, a citação do trabalho conforme a Associação Brasileira de Normas Técnicas (ABNT)); *descrição* (resumo e inovações do trabalho selecionado); *conjunto de dados* (descrição do conjunto de imagens utilizado para treinar o modelo); *resultados* (descrição dos resultados obtidos pelo trabalho selecionado); *discussão* (discussão autoral sobre os resultados, inovações e limitações do trabalho).

### 3. Resultados e discussões

Após a aplicação do método de revisão de literatura apresentado na seção 2, foram selecionados 36 trabalhos. A Figura 2 apresenta um gráfico com a quantidade de artigos obtidos ao longo dos anos. Conforme mostra o gráfico, há uma tendência de aumento na quantidade de artigos relacionados a partir de 2016. Esta tendência está relacionada à evolução das redes neurais convolucionais (aprendizagem profunda) que permitiram melhorar a forma de detecção de defeitos, além da evolução das placas gráficas e poder de processamento dos computadores.

Figura 2 – Distribuição da quantidade de trabalhos ao longo dos anos



Fonte: Autores

Nos primeiros anos os trabalhos utilizavam métodos clássicos nos quais as características eram extraídas por algum algoritmo. Esses algoritmos necessitavam que as informações presentes na imagem fossem extraídas manualmente, isto é, o algoritmo era escrito especificamente para realizar a tarefa, o que não é necessário com os modelos de aprendizagem profunda.

#### 3.1. Análise sistemática dos trabalhos levantados

Os trabalhos levantados foram sistematizados quanto a sua similaridade ao objeto de pesquisa. Além de informações quanto ao conjunto de dados, modelo, métricas de desempenho do

modelo e formas da resolução da detecção de objetos e detecção de defeitos. A partir dos dados bibliométricos, percebe-se que os trabalhos treinam e testam modelos específicos em conjuntos de dados próprios (criados pelos autores) para a resolução do problema de pesquisa.

Em relação aos modelos de aprendizagem profunda, a Tabela 1 a seguir apresenta a distribuição dos tipos de modelos pela quantidade de trabalhos que o empregaram. Vale ressaltar que um mesmo trabalho pode aplicar mais de um modelo para a resolução do problema de pesquisa. Os modelos mais utilizados são CNN (do inglês - *Convolutional Neural Network*), modelo próprio e SSD (do inglês - *Single Shot Detector*).

Tabela 1 - Modelos e número de trabalhos

Modelo	Número de trabalhos
<i>Convolutional Neural Network (CNN)</i>	10
Modelo próprio	9
<i>Single Shot Detector (SSD)</i>	6
<i>Support Vector Machine (SVM)</i>	3
Perceptron	2
<i>Regional Convolutional Neural Network (RCNN)</i>	2
<i>K-nearest neighbors (Knn)</i>	1
Leaky integrate and fire model	1
<i>FASTER Regional Convolutional Neural Network (FASTER RCNN)</i>	1
<i>FAST Regional Convolutional Neural Network (FAST RCNN)</i>	1
<i>You Only Look Once (YOLO)</i>	1
Estrutura de votação de janela deslizante	1
Correspondência de momentos de Fourier	1
<i>Template matching</i>	1

Fonte: Autores

Em relação aos conjuntos de dados, é evidente que os autores os constroem especificamente para a solução do problema de pesquisa do trabalho. Eles são denominados de conjuntos de dados próprios e geralmente possuem objetos que não são presentes nos conjuntos de *benchmark* (isto é, conjunto de imagens padrão usados para comparar o desempenho dos modelos), como, imagens com objetos manufaturados defeituosos.

Dessa forma, os conjuntos de dados próprios são os mais empregados, seguido dos MS COCO e PASCAL VOC. Esses dois têm uma grande aplicação, pois apresentam muitas classes distintas de objetos. O MS COCO se sobressai, pois apresenta objetos com tamanhos pequenos. A Tabela 2 a seguir apresenta a distribuição do uso dos conjuntos e a quantidade de trabalhos que as utilizam. Vale ressaltar que diversos trabalhos geralmente empregam mais de um tópico analisado no seu desenvolvimento.

Tabela 2 – Conjunto de dados e número de trabalhos

Nome	Tipo de aplicação	Número de trabalhos
Conjuntos de dados próprios (Levantados pelos autores dos trabalhos do estado da arte)	Cenários específicos	22
MS COCO (Microsoft <i>Common Objects in Context</i> )	Detecção genérica	4
PASCAL VOC (PASCAL <i>Visual Object Class</i> )	Detecção genérica	4
Caltech 101	Detecção genérica	2
Tilda dataset (Tianchi <i>fabric defect dataset</i> )	Detecção de defeitos	2
Kitti	Detecção de carros e pedestres	2
Caltech <i>pedestrian</i>	Detecção de pedetres	1
Caltech 256	Detecção genérica	1
Middlebury <i>dataset</i>	Detecção genérica	1
SUN ( <i>Scene UNderstanding</i> )	Detecção genérica	1
DAGM2007 ( <i>Deutsche Arbeitsgemeinschaft für Mustererkennung e.V.</i> )	Detecção de defeitos	1

Fonte: Autores

Por outro lado, para avaliar o desempenho dos modelos são aplicadas as métricas de desempenho. Dentre as métricas encontradas nos trabalhos selecionados a precisão média e a acurácia são as mais utilizadas. A preferência de aplicação dessas duas métricas está diretamente relacionada aos seus conceitos, já que elas permitem avaliar diretamente a proximidade entre o valor predito e o valor esperado. Além disso, são mais genéricas que as demais, como, por exemplo, interseção média sobre união utilizada para avaliar a qualidade da caixa delimitadora prevista pelo modelo. A quantidade de trabalhos e a métrica de desempenho utilizada para avaliar o modelo podem ser vistos na Tabela 3.

Tabela 3 –Métricas de desempenho e número de trabalhos

Métrica de desempenho	Número de trabalhos
Acurácia	9
Precisão média	9
Não especificado	5
<i>Mean Avarage Precision (mAP)</i>	3
<i>Recall</i>	3
<i>F-measure</i>	2
Matriz de confusão	2
Distância entre o ponto predito e o real	1
Acurácia média	1



Taxa média de erros	1
Taxa de sucesso	1
<i>G-mean</i>	1
Média	1
Tempo de execução	1
<i>False Positive Rate</i> (FPR)	1
<i>F1-score</i>	1
Área sob a curva	1
Precisão de pixel	1
Interseção sobre união	1
Interseção média sobre união	1

Fonte: Autores

A partir dos dados levantados, percebe-se um padrão utilizado na literatura que é o desenvolvido de um modelo próprio no qual os autores desenvolveram para a resolução do problema. Além disso, os trabalhos costumam construir um conjunto de dados próprio para o problema da pesquisa. Esses conjuntos de dados contêm imagens de objetos específicos em cenários específicos que costumam ser treinados para um modelo próprio. Ao final, esses modelos tem seu desempenho avaliado a partir de uma métrica de desempenho, em que sua maioria se emprega a acurácia ou a precisão média. Ambas são métricas que buscam avaliar os acertos do modelo no conjunto de dado.

### 3.2. Análise sistemática dos trabalhos relacionados

A partir dos 36 trabalhos selecionados durante a revisão de sistemática de literatura, 5 deles foram separados como os trabalhos mais relacionados com o objeto de pesquisa que é a detecção de objetos defeituosos com foco em objetos manufaturados aditivamente. Estes trabalhos realizaram algum tipo de detecção utilizando objetos ou discutem conceitos que podem ser adaptados para este cenário. A Tabela 4 a seguir apresenta estes trabalhos.

Tabela 4 – Trabalhos relacionados

Referência	Descrição	Conjunto de dados	Resultados	Discussão
(KIM <i>et al.</i> , 2012)	Proposta de um método para a detecção de objetos manufaturados. Um perceptron multicamada para realizar a detecção foi utilizado.	Conjunto de dados próprio contendo 7 tipos de objetos manufaturados.	Os autores conseguiram obter uma acurácia de 99,8%.	Um braço robótico realiza a separação dos objetos, o que tornou o sistema dependente de <i>hardware</i> externo.
(ZHOU <i>et al.</i> , 2018)	Proposta de uma abordagem para a	Conjunto de dados próprio com	Os autores obtiveram uma	A proposta não utiliza manufatura

	<p>detecção de defeitos em folhas decorativas. Para isso, um <i>ensemble</i> composto por duas redes CNN foi desenvolvido, sendo uma rede com a arquitetura Inception e a outra com a arquitetura MobileNet.</p>	<p>imagens de folhas decorativas, com as categorias de defeito: mancha, ponto, corte, fragmento, abrasão e colisão.</p>	<p>precisão de 95,6% usando a rede Inception e de 93,9% usando a rede MobileNet.</p>	<p>aditiva. Contudo, a aplicação das duas redes neurais para formar o <i>ensemble</i> permitiu que o modelo resultante fosse treinado com um pequeno conjunto de dados.</p>
(LEMOS <i>et al.</i> , 2019)	<p>Emprego de redes neurais artificiais para reconhecimento de defeitos em objetos manufaturados aditivamente.</p>	<p>Conjunto de dados próprio composto por 4 tipos de objetos que fazem parte de um botão de elevador.</p>	<p>Os autores demonstraram que utilizar aprendizado por transferência é uma boa opção para obter alto desempenho ao utilizar um conjunto de dados com poucas imagens.</p>	<p>O trabalho demonstrou que é possível realizar a detecção em tempo real. Contudo, utilizaram exemplos do mesmo objeto com ou sem defeito para realizar a detecção dos objetos.</p>
(AN <i>et al.</i> , 2020)	<p>Proposta de uma tecnologia para detectar defeitos em superfícies de textura baseada em aprendizado profundo. É proposto um método de detecção baseado na melhoria da rede neural FAST RCNN. É utilizada a rede RESNET-101 para a detecção de características básicas que auxilia na detecção de objetos pequenos.</p>	<p>O trabalho utiliza os conjuntos TILDA e <i>Tianchi fabric defects</i>. Para treinar o modelo, 5 categorias de defeitos são utilizadas: buraco, mancha, termina, lugar grosso e obstáculo.</p>	<p>A precisão média no conjunto de dados de defeitos atingiu 94,66% - o que é 4,35% superior ao modelo original.</p>	<p>O trabalho não aborda a manufatura aditiva. Os autores, também empregaram o mesmo modelo para realizar as duas tarefas, fazendo com que fosse necessário terem dois exemplos de cada objeto para que o modelo o detectasse.</p>
(LI; JIN; PAQUIT, 2021)	<p>Proposta de um esquema baseado em aprendizado de máquina para a detecção de defeitos geométricos em produtos</p>	<p>Conjunto de dados próprio composto por objetos manufaturados</p>	<p>Os resultados mostram que o <i>bagging</i> de árvores e a floresta aleatória são os modelos com</p>	<p>O trabalho aplica nuvem de pontos para detectar defeitos em objetos manufaturados.</p>

manufaturados. Para tanto, aditivamente, com e melhores Além disso, os autores empregaram sem defeito. previsibilidades utilizaram métricas diferentes classificadores: para o conjunto de de desempenho *Bagging* de árvores, dados. pouco usuais para aumento de gradiente, contornarem o floresta aleatória, K-NN e problema de falta máquina vetorial com de balanceamento suporte linear. das classes.

---

Fonte: Autores

Dos trabalhos relacionados, apenas os trabalhos de Zhou *et al.* (2018) e An *et al.* (2020) não empregaram seus modelos em imagens de objetos manufaturados aditivamente. An *et al.* (2020) propuseram uma melhoria em um modelo do estado da arte: a FAST RCNN para realizar a detecção de defeitos em superfícies de textura. Eles conseguiram obter uma precisão média de 94,66% na detecção, contudo empregaram um único modelo para realizar as tarefas de detecção de objetos e detecção de defeitos.

Por outro lado, Zhou *et al.* (2018) empregaram duas redes CNN, formando um *ensemble* para realizar a tarefa de detecção. Isso contornou o problema de poucos dados disponíveis para o treino e teste dos modelos. Os autores conseguiram obter precisão de classificação em duas arquiteturas distintas de CNN, Inception e MobileNet, sendo que a precisão de classificação delas no conjunto de teste é de 95,6% e 93,9%, respectivamente. O emprego de CNNs para a tarefa de classificação de defeitos se evidencia como uma estratégia eficaz, uma vez que esta categoria de rede pode executar a classificação binária de forma ágil e eficiente. Além disso, CNNs são reconhecidas por sua alta robustez e ampla utilização em trabalhos considerado estado-da-arte no campo do aprendizado de máquina.

Em contrapartida, Lemos *et al.* (2019) e Li, Jin e Paquit (2021) exploraram a detecção de defeitos em objetos manufaturados em conjuntos de dados que apresentam um número reduzido de imagens. Os autores adotaram diferentes modelos de aprendizado de máquina para conduzir suas análises. Lemos *et al.* (2019) propuseram a utilização de aprendizado por transferência para contornar o problema de poucas imagens, por meio da customização de um modelo já previamente treinado e testado para detectar outras classes de objetos.

Por sua vez, Li, Jin e Paquit (2021) avaliaram diversos tipos de classificadores para desenvolver sua abordagem, necessitando criar novas formas de avaliação dos modelos a fim de lidar com o problema de desbalanceamento das classes. Em ambas os trabalhos, foi possível constatar que a detecção de defeitos em objetos manufaturados produzidos por meio da fabricação aditiva pode ser realizada mesmo em conjuntos de dados com poucas imagens.

Por fim, Kim *et al.* (2012) desenvolveram um sistema funcional capaz de realizar a detecção automática de defeitos em objetos manufaturados. O sistema é baseado em um modelo de Perceptron multicamadas, que é responsável por executar a tarefa de detecção. Para tanto, os objetos são transportados por uma esteira e um braço robótico é responsável por retirar cada objeto e posicioná-lo em frente a uma câmera, possibilitando a realização da detecção. O modelo proposto atingiu uma acurácia de detecção de 99,8%. Contudo, o trabalho apresentou uma grande limitação, que se trata da dependência de um *hardware* externo, o braço robótico, o que pode inviabilizar sua aplicação em diferentes cenários.

Partindo destes pressupostos, é visível que a construção de um sistema de detecção de objetos manufaturados defeituosos é viável. Uma vez que os modelos do estado da arte são capazes de realizar tal tarefa, para isso eles devem ser modificados para satisfazerem as condições do cenário. O sistema deve ser formado por uma câmera para captar as imagens dos objetos, uma unidade de processamento responsável por processar a imagem e mostrar o resultado para o usuário. Este modelo deve antes ser treinado em um conjunto de dados que contenha exemplos de objetos com e sem defeitos, e após avaliados a partir de uma métrica de desempenho. Como a amostragem de objetos manufaturados aditivamente é difícil e existem poucos conjuntos de dados relacionados, é possível empregar a técnica de aprendizagem por transferência para contornar o problema de poucas imagens.

Além disso, os trabalhos relacionados aplicam um modelo para realizar as duas tarefas de detecção do objeto e da classificação do objeto como defeituoso ou não defeituoso. Contudo, é possível realizar a separação de responsabilidade e separar as duas tarefas em dois modelos distintos. Isso permite que esses modelos sejam treinados e testados de forma independente e possibilita o aumento da qualidade da detecção; além disso, fornece mais informações para o usuário final tomar decisões (DA SILVA; ALCALÁ; BARBOSA, 2022).

### 3.3. Resposta das questões de pesquisa

- I. Quais são os modelos de aprendizagem profunda mais utilizados na literatura para a detecção de objetos defeituosos e, em especial, para a detecção de objetos manufaturados aditivamente?

Os modelos mais utilizados na literatura são os CNN, modelos próprios e SSD. A CNN é um modelo robusto e altamente testado e revisado na literatura. Já o modelo próprio consiste na melhoria ou criação de um modelo para a resolução de um problema específico. Portanto, esses dois são amplamente empregados devido a sua versatilidade. Por fim, o SSD é um modelo totalmente voltado para a detecção de objetos. Ele apresenta diversas vantagens, dentre elas a

possibilidade de execução em tempo real que incrementa seu uso. Além disso, em relação à detecção de objetos defeituosos é um dos modelos mais aplicados, devido à sua capacidade de realizar a detecção em uma única etapa e permitir a aplicação em tempo real.

II. Quais são os conjuntos de dados mais utilizados na literatura para o desenvolvimento de modelos de aprendizagem profunda?

Os conjuntos de dados próprios são os mais utilizados, seguido dos conjuntos de dados MS COCO e PASCAL VOC. Esses dois últimos têm grande aplicação, pois apresentam muitas classes distintas de objetos. O MS COCO se sobressai, pois apresenta objetos pequenos. Por outro lado, os conjuntos de dados próprios são construídos especificamente para a resolução do problema, permitindo o treino e o teste do modelo. Além de serem amplamente empregados em abordagens de transferência de aprendizagem, onde um modelo previamente treinado em um conjunto de dados de *benchmark* é retreinado no conjunto próprio. Para a manufatura aditiva, os modelos próprios são dominantes visto que ainda não existe um conjunto de dados de *benchmark* com objetos manufaturados aditivamente.

III. Quais são as métricas de desempenho mais utilizadas?

As métricas mais empregadas para a avaliação de modelos são a precisão média e a acurácia, uma vez que essas permitem uma avaliação direta da proximidade entre o valor esperado e o valor previsto. Ademais, tais métricas são mais abrangentes em comparação a outras, como a interseção média sobre união, que é utilizada para avaliar a qualidade das caixas delimitadoras previstas pelo modelo.

IV. Como os autores resolvem a tarefa de detecção de objetos?

Na literatura costuma-se resolver a tarefa de detecção de objetos a partir do treino de um modelo do estado da arte, como, a CNN, SSD, FASTER RCNN. Os dados de treino são o conjunto de dados próprio que os autores constroem, após retreinado o modelo é testado e validado.

V. Como os autores resolvem a tarefa de detecção de defeitos?

Os autores se concentram em levantar os dados e então treinar uma rede de classificação que fica responsável por receber a imagem e predizer se o objeto é defeituoso ou predizer qual o defeito presente no objeto. Estes trabalhos se concentraram apenas em definir se o objeto estava ou não defeituoso, sendo que nenhum deles explorou a correlação entre os defeitos e a causa.

#### 4. Conclusões

A detecção de objetos defeituosos geralmente é realizada a partir da coleta de imagens para formar o conjunto de dados, escolha de um modelo, treino, teste e avaliação do modelo. O

presente trabalho apresentou uma revisão sistemática da literatura sobre a detecção de objetos e defeitos, e em especial, como objetos manufaturados aditivamente têm sido abordados. Foram discutidos diversos trabalhos da literatura, além da resposta de algumas perguntas pertinentes. Nesse caso, foi identificado que os autores geralmente optam por melhorar ou desenvolver um modelo do estado da arte para realizar a detecção, além de treinarem e testarem esse modelo também com um conjunto de dados levantado especificamente para o trabalho.

Também foi apresentada uma análise sistemática dos dados bibliométricos e de 5 trabalhos do estado da arte referentes ao tema de detecção de objetos defeituosos manufaturados aditivamente. Nestes trabalhos foram empregados modelos de aprendizado de máquina para realizar a detecção de objetos defeituosos, além da discussão sobre a resolução de problemas encontrados durante o desenvolvimento dos modelos. Por fim, sugere-se o uso da transferência de aprendizagem para realizar a detecção em conjuntos com poucas amostras de imagens, além do emprego de modelos do estado da arte para realizar a detecção, e a separação da responsabilidade entre as duas tarefas distintas: a detecção de objetos e a detecção de defeitos.

## 5. 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

ALPAYDIN, E. **Introduction to machine learning**. Cambridge, Massachusetts: The Mit Press, 2014.

AN, M. *et al.* Fabric defect detection using deep learning: An Improved Faster R-approach. **2020 International Conference on Computer Vision, Image and Deep Learning (CVIDL)**, jul. 2020.

CHEN, L.-F.; SU, C.-T.; CHEN, M.-H. A Neural-Network Approach for Defect Recognition in TFT-LCD Photolithography Process. **IEEE Transactions on Electronics Packaging Manufacturing**, v. 32, n. 1, p. 1–8, jan. 2009.

DA SILVA, L. M.; ALCALÁ, S. G. S.; BARBOSA, T. M. G. D. A. **PROPOSTA DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE DEFEITOS EM PEÇAS MANUFATURADAS ADITIVAMENTE**. Congresso técnico científico da engenharia e da agronomia (CONTEC). **Anais...**2022.

FRAZIER, W. E. Metal Additive Manufacturing: A Review. **Journal of Materials Engineering and Performance**, v. 23, n. 6, p. 1917–1928, 8 abr. 2014.

GIL, A. A. C. **Como elaborar projetos de pesquisa**. [s.l.] Éditeur: São Paulo: Atlas, 2010.

GONZALEZ-GUTIERREZ, J. *et al.* Additive Manufacturing of Metallic and Ceramic Components by the Material Extrusion of Highly-Filled Polymers: A Review and Future Perspectives. **Materials**, v. 11, n. 5, p. 840, 18 maio 2018.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, Massachusetts: The Mit Press, 2016.

HORSMAN, G.; LYLE, J. R. Dataset construction challenges for digital forensics. **Forensic Science International: Digital Investigation**, v. 38, p. 301264, set. 2021.

HUANG, S.-H.; PAN, Y.-C. Automated visual inspection in the semiconductor industry: A survey. **Computers in Industry**, v. 66, p. 1–10, jan. 2015.

KIM, K. *et al.* Object recognition for cell manufacturing system. **2012 9th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)**, nov. 2012.

LEMOS, C. B. *et al.* Convolutional Neural Network Based Object Detection for Additive Manufacturing. **2019 19th International Conference on Advanced Robotics (ICAR)**, dez. 2019.

LI, R.; JIN, M.; PAQUIT, V. C. Geometrical defect detection for additive manufacturing with machine learning models. **Materials & Design**, v. 206, p. 109726, ago. 2021.

NASIRI, S.; KHOSRAVANI, M. R. Machine learning in predicting mechanical behavior of additively manufactured parts. **Journal of Materials Research and Technology**, jul. 2021.

NGO, T. D. *et al.* Additive manufacturing (3D printing): A review of materials, methods, applications and challenges. **Composites Part B: Engineering**, v. 143, p. 172–196, jun. 2018.

PRAKASH, K. S.; NANCHARAIH, T.; RAO, V. V. S. Additive Manufacturing Techniques in Manufacturing - An Overview. **Materials Today: Proceedings**, v. 5, n. 2, Part 1, p. 3873–3882, 1 jan. 2018.

SITOTAW, D. B. *et al.* Additive Manufacturing and Textiles—State-of-the-Art. **Applied Sciences**, v. 10, n. 15, p. 5033, 22 jul. 2020.

TABERNIK, D. *et al.* Segmentation-based deep-learning approach for surface-defect detection. **Journal of Intelligent Manufacturing**, v. 31, n. 3, p. 759–776, 15 maio 2019.

VANDERPLOEG, A.; LEE, S.-E.; MAMP, M. The application of 3D printing technology in the fashion industry. **International Journal of Fashion Design, Technology and Education**, v. 10, n. 2, p. 170–179, 24 ago. 2016.

WU, X.; SAHOO, D.; HOI, S. C. H. Recent advances in deep learning for object detection. **Neurocomputing**, 10 ago. 2020.