



**PROJETO DE GRADUAÇÃO**

**EXPLORANDO A UTILIZAÇÃO DE GRAFOS E  
IMAGENS 2D PARA O RECONHECIMENTO  
AUTOMÁTICO DE ETAPAS EM PROCESSOS DE  
MONTAGEM UTILIZANDO INTELIGÊNCIA  
ARTIFICIAL**

Por,

**Isabel Caroline Gomes Giannecchini**

Brasília, 13 de setembro de 2024

**UNIVERSIDADE DE BRASÍLIA**  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO

UNIVERSIDADE DE BRASÍLIA

Faculdade de Tecnologia

Departamento de Engenharia de Produção

## PROJETO DE GRADUAÇÃO

# EXPLORANDO A UTILIZAÇÃO DE GRAFOS E IMAGENS 2D PARA O RECONHECIMENTO AUTOMÁTICO DE ETAPAS EM PROCESSOS DE MONTAGEM UTILIZANDO INTELIGÊNCIA ARTIFICIAL

POR,

**Isabel Caroline Gomes Giannecchini**

Relatório submetido como requisito parcial para obtenção  
do grau de Engenheiro de Produção.

**Banca Examinadora**

Prof. Sanderson C. M. Barbalho, UnB/ EPR (Orientador)

Prof. Díbio Leandro Borges, UnB/ IE-CIC

Prof. Eugênia C. M. da Silva, UnB/ EPR

Brasília, 13 de setembro de 2024

## **Dedicatória**

*A todos que me inspiraram a  
continuar.*

*Isabel Caroline Gomes Giannecchini*

## **Agradecimentos**

*Aos amigos que a graduação me deu, Guilherme Andrey, Maria Ramos e Ivan Cunha e ao amigo que a graduação me permitiu reencontrar, Mateus Vieira, muito obrigada por todas as vezes que vocês me viram chorar por todos os motivos possíveis. Se hoje eu não desisti de entregar um TCC com um pedacinho sobre inteligência artificial foi porque vocês não me deixaram desistir. Saibam que vocês são algumas das pessoas que mais me inspiram na vida inteira.*

*Aos amigos que a Faculdade de Tecnologia me deu, Luciano Soto, Pedro Yannoulas e Luis Weaver por todo o apoio e toda a dedicação que vocês tiveram para apoiar o desenvolvimento de tudo o que eu “apronto”.*

*Ao meu melhor amigo, Gustavo Willy, que me apoia e puxa minha orelha para tudo, me ensina valiosíssimas lições de vida, amizade, como ser uma boa pessoa, como ser um bom amigo e fez de tudo para estar presente me apoiando nesse momento.*

*Ao Cubo, que eu não sei explicar o quanto é uma pessoa especial na minha vida. Obrigada por tudo o que você já fez por mim e eu espero de verdade que um dia eu possa ser para você pelo menos 1% do que você é por mim.*

*Ao amor da minha vida, Kleber Lucas, por ter impresso apenas as páginas ímpares, me aturar durante toda a escrita desse projeto, durante todo o meu último ano da graduação e irá me aturar até que a morte nos separe.*

*Aos meus pais, Celma Maria Gomes da Silva e Sabatino Giannecchini Neto, que estão presentes sempre.*

*À minha avó, Maria Cristina Gomes da Silva que é a pessoa que eu mais amo no mundo inteiro, exemplo de humildade, de amor e de carinho.*

*Aos professores Thomas Williams e Cynthia Kyaw que foram os primeiros a acreditar no meu potencial e me apoiaram na decisão de mudar de curso. Ao professor André Von Borries Lopes, que acreditou no projeto de extensão que eu deixo de legado para a UnB, o Mural, e apoiou seu desenvolvimento para fazer do mundo um lugar um pouquinho melhor. Às professoras Carla Borges e Patrícia Guarnieri por possibilitarem meu desenvolvimento profissional em áreas diferentes por meio da divulgação científica. À professora Andrea*

*dos Santos por ter acreditado em mim e por ter me indicado o professor Sanderson. E aos professores da Engenharia de Produção por participarem da minha formação profissional.*

*Por fim, ao meu orientador, professor Sanderson Barbalho, a quem admiro muito e agradeço demais por permitir que eu esteja fazendo parte do grupo de pesquisa hoje, por tudo o que o senhor me ensinou e por todo o apoio que o senhor me deu.*

*Isabel Caroline Gomes Giannecchini*

---

## RESUMO

Neste estudo, apresenta-se uma abordagem para sistemas de assistência à montagem, destacando a transformação de modelos BPMN em grafos como a principal contribuição. Essa transformação permite uma representação mais clara e estruturada dos processos de montagem, facilitando a sincronização, a automação e o controle de qualidade. A aplicação prática desse conceito é demonstrada através da montagem de um protótipo de caminhão, utilizando manufatura aditiva. O grafo resultante não apenas define a sequência das atividades, mas também sincroniza o estado real da montagem com o estado percebido pelo sistema digital. Essa virtualização do processo é importante para testar a performance do sistema e aprimorar a eficiência dos sistemas de assistência à montagem baseados em inteligência artificial. Ao integrar essa metodologia, espera-se que os sistemas desenvolvidos contribuam de forma mais assertiva para a qualidade e eficiência em processos de montagem manual, alinhando-se aos princípios da Indústria 4.0.

Palavras-Chave: Grafo, Processo de Montagem, Qualidade, Indústria 4.0, Inteligência Artificial

---

## ABSTRACT

This study presents an approach for assembly assistance systems, highlighting the transformation of BPMN models into knowledge graphs as the main contribution. This transformation allows for a clearer and more structured representation of assembly processes, facilitating synchronization, automation, and quality control. The practical application of this concept is demonstrated through the assembly of a truck prototype, using additive manufacturing. The resulting graph not only defines the sequence of activities, but also synchronizes the actual state of the assembly with the state perceived by the digital system. This process virtualization is important for testing system performance and improving the efficiency of artificial intelligence-based assembly assistance systems. By integrating this methodology, it is expected that the systems developed will contribute more assertively to quality and efficiency in manual assembly processes, aligning with the principles of Industry 4.0.

Keywords: Graph, Assembly Process, Quality, Industry 4.0, Artificial Intelligence

# SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>1</b>
1.1. Justificativa.....	1
1.2. Objetivos do projeto.....	3
1.2.1.    Objetivos Específicos.....	4
1.3. Escopo do projeto.....	4
1.4. Estrutura do trabalho .....	5
<b>2 MÉTODO DE PESQUISA .....</b>	<b>6</b>
2.1. Classificação da pesquisa .....	6
2.2. Metodologia.....	9
2.2.1.    Resumo.....	9
2.2.2.    Softwares .....	9
2.2.3.    Desenvolvimento do grafo .....	10
2.2.4.    Construção do conjunto de dados .....	11
2.2.1.    Construção do modelo de classificação de imagens .....	12
<b>3 REVISÃO BIBLIOGRÁFICA.....</b>	<b>13</b>
3.1. Qualidade.....	13
3.1.1.    Qualidade no processo de montagem .....	15
3.1.2.    Controle de qualidade na indústria 4.0 .....	16
3.2. Inteligência artificial .....	17
3.2.1.    Sistemas de inteligência artificial para o controle de qualidade .....	23
3.2.2.    Controle de qualidade em um sistema de assistência à montagem .....	24
3.3. Estado da arte .....	25
3.3.1.    Aplicação de grafos a sistemas de assistência à montagem .....	36
3.4. Caracterização do caso estudado neste trabalho.....	38
<b>4 APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA SISTEMAS DE SUPORTE A MONTAGEM.....</b>	<b>40</b>
4.1. Descrição geral do grafo representativo do processo de montagem .....	40
4.2. Definição dos nós do grafo representativo do processo de montagem do protótipo de caminhão.....	43
4.3. Definição das arestas do grafo representativo do processo de montagem do protótipo de caminhão.....	47
4.4. Construção do processo de montagem em uma estrutura de grafo.....	48

4.5. Detalhamento da estrutura .....	49
4.6. Detalhamento Nós e Arestas.....	51
4.7. Construção de conjunto de dados para treinamento de algoritmo inteligente .....	54
4.7.1. Data Augmentation .....	54
4.7.2. Conversão do formato de arquivo.....	56
4.7.3. Rotação.....	56
4.7.4. Alterações no zoom das imagens .....	57
4.7.5. Remoção de imagens .....	58
4.7.6. Mudança no plano de fundo das imagens .....	59
4.7.7. Algoritmo.....	61
4.8. Modelo de reconhecimento de objetos.....	63
4.8.1. Transfer Learning.....	63
4.8.2. Construção do Modelo .....	63
4.8.3. Ajustes do treinamento .....	64
4.8.4. Resultados do treinamento .....	66
<b>5 CONCLUSÃO .....</b>	<b>71</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>74</b>

## LISTA DE FIGURAS

<b>Figura 1</b> - Foto do protótipo de caminhão do projeto AuQua .....	3
<b>Figura 2</b> - Resumo das etapas da metodologia .....	9
<b>Figura 3</b> - Imagem do modelo CAD do protótipo do caminhão do projeto AuQua.....	11
<b>Figura 4</b> - Árvore de decisão .....	19
<b>Figura 5</b> - Representação de um algoritmo de aprendizagem por reforço genérico.....	20
Figura 6 - Representação da propagação de um impulso nervoso em um neurônio biológico .....	21
Figura 7 - Modelo de neurônio matemático e equações correspondentes de McCulloch e Pitts.....	22
Figura 8 - Representação simplificada de um neurônio matemático.....	23
<b>Figura 9</b> - Diagrama de acoplamento bibliográfico destacados por ano .....	30

<b>Figura 10</b> - Diagrama de cocitação.....	31
<b>Figura 11</b> - Diagrama de palavras-chave.....	34
<b>Figura 12</b> - Diagrama da proposta inicial do sistema AuQua .....	38
<b>Figura 13</b> - Diagrama exemplificando a estrutura de um grafo direcional.....	41
<b>Figura 14</b> - Diagrama da estrutura de grafos pensada construída com estados de montagem .....	42
<b>Figura 15</b> - Diagrama do grafo representativo do processo de montagem do caminhão ..	50
<b>Figura 16</b> - Final do Estado Eixo-Semi-Montado .....	50
<b>Figura 17</b> - Subconjunto final do estado Cabine Plataforma.....	51
<b>Figura 18</b> - Coleção de imagens das partes do caminhão em vista lateral esquerda .....	56
<b>Figura 19</b> - Imagens com vistas em ângulos aleatórios da peça 'cabine' .....	57
<b>Figura 20</b> - Zooms diferentes para a cabine do caminhão.....	58
<b>Figura 21</b> - Exemplo de imagem com foco no espaço ao redor da peça (completamente preta).....	59
<b>Figura 22</b> - Possibilidades de plano de fundo.....	60
<b>Figura 23</b> - Peça da cabine com e sem plano de fundo .....	60
<b>Figura 24</b> - Comparação entre acurácia de treino e teste de um modelo treinado com 100 épocas .....	65
<b>Figura 25</b> - Resultados de treinamento do modelo .....	66
<b>Figura 26</b> - Resultados do teste do modelo .....	68
<b>Figura 27</b> - Matriz de confusão com os resultados do modelo.....	69

## LISTA DE GRÁFICOS

<b>Gráfico 1</b> - Proporção de trabalhos por tipo de publicação .....	25
<b>Gráfico 2</b> – Quantidade de publicações por ano .....	26
<b>Gráfico 3</b> – Quantidade de publicações por país .....	28

## LISTA DE TABELAS

Tabela 1 - Classificação e descrição de tipos de pesquisa.....	6
<b>Tabela 2</b> - Referências em cocitação bibliográfica.....	31
<b>Tabela 3</b> - Atributos de estados de montagem.....	43
<b>Tabela 4</b> – Subconjuntos triviais do protótipo do caminhão .....	44
<b>Tabela 5</b> - Composição de subconjuntos .....	46
<b>Tabela 6</b> - Quantidades de cada peça na composição de cada subconjunto .....	47
<b>Tabela 7</b> - Atributos nós .....	52
<b>Tabela 8</b> - Atributos arestas .....	53
<b>Tabela 9</b> - Quantidade de imagens por classe.....	62
<b>Tabela 10</b> - Quantidade de Parâmetros do modelo Xception .....	64
<b>Tabela 11</b> - Resumo do Modelo implementado.....	64
<b>Tabela 12</b> - Quantidade de verdadeiros positivos por classe.....	69

## LISTA DE ALGORITMOS

<b>Algoritmo 1</b> - Real Time Module Operation (Fonte: Fault Detection and Isolation in Industrial Processes Using Deep Learning Approaches) .....	27
<b>Algoritmo 2</b> - Geração do grafo representativo do processo de montagem manual do caminhão .....	49
<b>Algoritmo 3</b> - Geração do conjunto de dados de imagens do caminhão .....	62

## LISTA DE SÍMBOLOS

Siglas (Em ordem alfabética)

AAS	Assembly Assistance System
CNI	Confederação Nacional da Indústria
CPS	Sistemas Cyber Físicos
IA	Inteligência Artificial
YOLO	You Only Look Once

# 1 INTRODUÇÃO

*Este capítulo apresenta considerações preliminares a respeito do conteúdo do presente Projeto de Graduação. São abordados a justificativa e objetivos do trabalho, bem como aspectos sobre a estrutura do trabalho e seu escopo.*

## 1.1. Justificativa

A Indústria 4.0 é um termo alemão que trata do salto de mudanças tecnológicas e inovações que permitem um grau disruptivo de digitalização na produção industrial (DA SILVA et al., 2021). Dentre as tecnologias disruptivas para aplicação industrial, estão tecnologias de inteligência artificial (IA) embarcada nos processos industriais e sensores capazes de realizar processamento de dados em tempo real para avaliar indicadores importantes da linha de produção.

Entretanto, para garantir a aplicação dessas tecnologias na indústria, é necessário a alocação de recursos com a finalidade de digitalizar a linha de produção. A intenção de investimento na indústria brasileira, de acordo com a CNI em novembro de 2023, está em 55,6 pontos, desde o início dos dados disponíveis, a partir de novembro de 2013, o maior índice foi de 61,5 em janeiro de 2014 (CNI - CONFEDERAÇÃO NACIONAL DA INDÚSTRIA, 2023). Este indicador reflete o percentual de empresas industriais de transformação e extração que pretendem investir em digitalização nos próximos 6 meses, de acordo com a CNI. Ainda de acordo com a Confederação, quanto maior o investimento, maior o crescimento da economia, dessa forma, conhecer a intenção de investimento ajuda a prever o que irá ocorrer com o crescimento da indústria e da economia como um todo. O índice de 55,6 pontos, indica que mais da metade das empresas do setor industrial brasileiro pretendem realizar investimentos o que pode indicar uma tendência de adoção de novas tecnologias (CNI - CONFEDERAÇÃO NACIONAL DA INDÚSTRIA, 2023).

Um dos indicadores importantes em uma linha de produção é a qualidade. Em seus diferentes enfoques, a qualidade é qualquer propriedade de produtos, materiais ou processos necessários para conseguir a adequação de seu uso (TOLEDO et al., 2014). No enfoque baseado na fabricação, a qualidade é a conformidade com as especificações, um desafio para a qualidade é como medir as especificações das unidades produzidas em uma linha de produção (TOLEDO

et al., 2014). Com a pressão por qualidade mais alta, novas possibilidades para investimentos em tecnologias de automação e robotização da confecção surgem para coletar indicadores de qualidade por meio de sensores, em tempo real, otimizando as unidades produtivas (DA SILVEIRA BRUNO, 2016).

O estudo da aplicação de inteligência artificial em linhas de montagem é crescente e atua como parte integrante da indústria 4.0 (BEZERRA et al., 2023), uma das aplicações da inteligência artificial na indústria é a detecção ou classificação de falhas. Ainda que, atualmente, estejamos em uma fase de princípio de discussões acerca do tema, é possível entender uma crescente no interesse acerca de pesquisas relacionadas com a detecção de falhas na indústria utilizando técnicas de inteligência artificial, sobretudo a partir do ano de 2023 (BEZERRA et al., 2023).

Separando os processos existentes na indústria, existe o processo de montagem, aquele que compreende a junção de peças em um conjunto finito de tarefas em uma ordem pré-determinada de forma a compor um produto funcional (FERNANDES; FILHO, 2019). Nesse processo, o uso de técnicas de *machine learning*, ou aprendizado de máquina, vem sendo aplicado como uma forma de melhorar a flexibilidade do processo, bem como sua rastreabilidade (DE QUEIROZ et al., 2023). Junto com isso, a utilização de técnicas de aprendizado de máquina, também pode ser também aplicada para a detecção de falhas em processos de montagem industrial (BEZERRA et al., 2023; DE QUEIROZ et al., 2023).

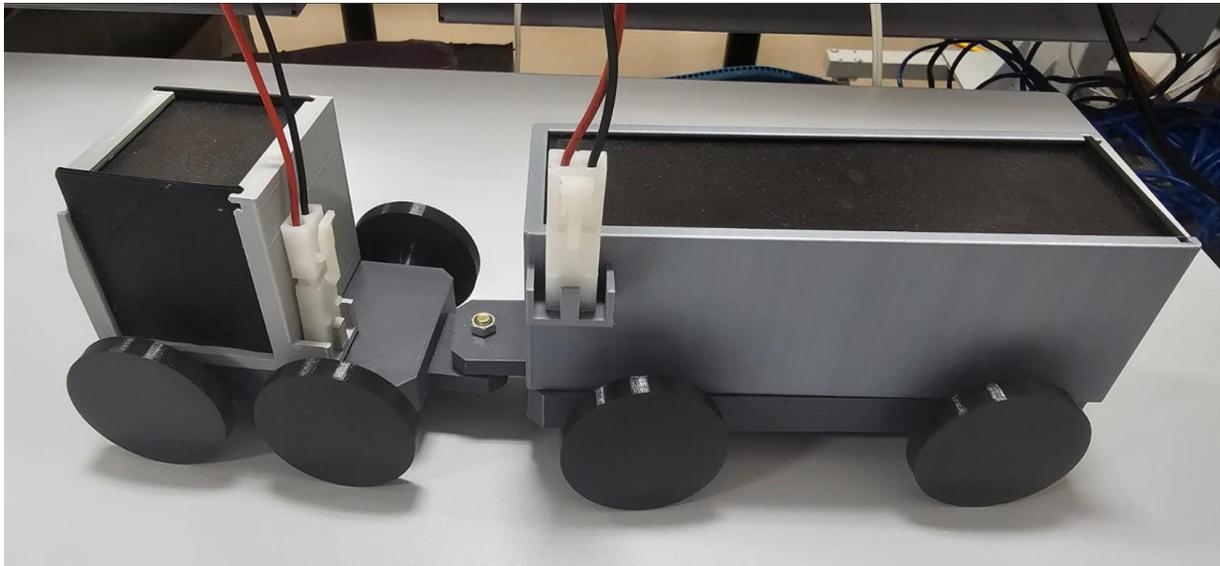
A detecção de falhas é uma das formas de apoiar na promoção da qualidade em processos (TOLEDO et al., 2014), com isso, uma forma de extrapolar o uso de inteligência artificial e suas variadas técnicas, como o aprendizado de máquina, para detecção de falhas é por meio de sua utilização na garantia ou melhora da qualidade geral dos resultados dos processos de uma indústria. Isso pode ser conduzido por meio da criação de um sistema que tenha a qualidade como o foco principal dos resultados de sua implementação (THAMM et al., 2020).

Uma das formas de promover a qualidade em linhas de montagem é por meio da incorporação de sistemas de assistência à montagem — AAS — nestas. Sistemas atuais de assistência a montagem focam no aumento da qualidade em linhas de montagem por meio da redução de possibilidades de falha e podem utilizar diferentes formas de implementação para garantir seu desempenho (THAMM et al., 2020).

O projeto AuQua — *Augmented Quality* — é fruto do conjunto de esforços de pesquisadores brasileiros e alemães para propor um sistema de assistência à montagem baseado em inteligência artificial e realidade aumentada para promover maior qualidade para linhas de

produção e montagem industrial, de forma escalável e promovendo maiores discussões e inovações no tema (THAMM et al., 2020).

Para compor os resultados do projeto, este trabalho busca aplicar o estudar novas formas de virtualizar etapas da produção por meio de grafos e inteligência artificial. Essa avaliação foi realizada por meio de testes com o protótipo de caminhão (Figura 1) do projeto AuQua.



**Figura 1** - Foto do protótipo de caminhão do projeto AuQua

## **1.2. Objetivos do projeto**

A interação humano-computador pode ser estimulada por meio da facilitação de processos manuais por meio da tecnologia, como, por exemplo, em processos manuais de montagem, computadores podem passar instruções para os trabalhadores (RIEDEL et al., 2021; TORKUL; SELVI; ŞIŞCI, 2022; ZAMORA-HERNÁNDEZ et al., 2021). Ou auxiliar na prevenção de falhas, incluindo problemas com a ergonomia do processo (TORKUL; SELVI; ŞIŞCI, 2022).

A fim de promover uma nova forma de virtualizar o processo de montagem e propor uma solução para a sincronização do sistema de assistência à montagem digital com o processo de montagem realizado pelo operador de montagem, esse estudo tem como objetivo estudar outras aplicações para técnicas de aprendizagem profunda, método de inteligência computacional que evita a necessidade de operadores humanos especificarem formalmente todo o conhecimento que o computador necessita para aprender conceitos (GOODFELLOW; BENGIO;

COURVILLE, 2016) para automação da sincronização dos sistemas visando o apoio ao processo manual de montagem.

### 1.2.1. Objetivos Específicos

A partir do objetivo geral apresentado, é possível identificar os objetivos específicos desse projeto, sendo ele:

Desenvolvimento de uma estrutura de grafos para representar o processo de montagem do protótipo de caminhão (Figura 1) como forma de prova de conceito.

O estudo da melhoria da qualidade do processo por meio da incorporação de um grafo para a automação da sincronização do estado do sistema e consequente prevenção de falhas.

Construção de um conjunto de dados de treinamento para permitir a criação e aprendizado de modelos baseados em inteligência artificial e sua incorporação em sistemas de assistência à montagem.

Treinamento de um modelo de classificação de imagens como forma de prova de conceito para testar a capacidade de sincronização do estado real e virtual de montagem.

### 1.3. Escopo do projeto

O projeto irá realizar a adaptação e testagem do protótipo de algoritmo de *Deep Learning* (ou aprendizado profundo) para avaliar a qualidade da montagem de um protótipo de caminhão feito por meio de manufatura aditiva para melhorar a qualidade do algoritmo e permitir um próximo passo de desenvolvimento deste para sua futura aplicação em contexto industrial. O projeto se encontra no nível de maturidade tecnológica 4, com a validação, em ambiente laboratorial, componentes e arranjos experimentais do sistema proposto (EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, 2023).

A melhoria testada nesse projeto será a formatação das instruções de montagem em uma estrutura de grafo para comunicar ao sistema de assistência à montagem, quais as atividades do processo de montagem e quais os estados do sistema ao longo da execução do processo (CHEN et al., 2020).

## **1.4. Estrutura do trabalho**

Este trabalho está estruturado em partes, em cada uma delas, capítulos apresentam o assunto separado por tema. Para a primeira parte, com a teoria por trás do projeto, o primeiro deles traz uma introdução sobre o problema endereçado no projeto e discute as justificativas e objetivos da solução proposta. O segundo demonstra a metodologia realizada para executar o trabalho apresentado no capítulo inicial. Já o terceiro, traz um resumo do que foi encontrado na literatura científica clássica e atual acerca da temática do projeto para embasar seu desenvolvimento.

Para a parte prática do trabalho, o quarto capítulo trás as especificações de como foi realizada a preparação do sistema de assistência à montagem a partir do mapeamento do processo de montagem no caso do protótipo de caminhão do projeto AuQua, bem como de como foi realizada a aplicação de um algoritmo de inteligência artificial como prova de conceito para o conjunto de dados de treinamento do sistema de assistência a montagem do protótipo do caminhão do projeto AuQua.

Ao final, são apresentadas, junto das conclusões do trabalho, possibilidades de próximas etapas para o aprimoramento dos resultados deste trabalho e continuidade do projeto.

## 2 MÉTODO DE PESQUISA

*Neste capítulo será abordada a metodologia de pesquisa utilizando, classificando a pesquisa em questão e definindo as atividades necessárias para seu desenvolvimento.*

### 2.1. Classificação da pesquisa

O método científico é o caminho para chegar a um fim (TARTUCE, 2006). Este permite a formulação de resultados a partir de uma análise rigorosa e extração de dados de objetos de estudo (TARTUCE, 2006). O método científico compreende um conjunto de dados iniciais e um sistema de operações ordenadas adequado para a formulação de conclusões, de acordo com certos objetivos predeterminados (TARTUCE, 2006).

Uma pesquisa é a procura de respostas para perguntas propostas (SILVA; MENEZES, 2001). Essa procura pode acontecer de diferentes formas, a essas formas se dão o nome de tipos de pesquisa. Uma pesquisa pode ser classificada de acordo com a sua natureza, abordagem, objetivos e procedimentos técnicos (Tabela 1) (SILVA; MENEZES, 2001).

**Tabela 1 - Classificação e descrição de tipos de pesquisa**

Natureza	Básica	Objetiva gerar conhecimentos novos úteis para o avanço da ciência sem aplicação prática prevista. Envolve verdades e interesses universais.
	Aplicada	Objetiva gerar conhecimentos para aplicação prática dirigidos à solução de problemas específicos. Envolve verdades e interesses locais.
Abordagem	Quantitativa	Considera que tudo pode ser quantificável, o que significa traduzir em números opiniões e informações para classificá-las e analisá-las. Requer o uso de recursos e de técnicas estatísticas (percentagem, média, moda, mediana, desvio-padrão, coeficiente de correlação, análise de regressão etc.).
	Qualitativa	Considera que há uma relação dinâmica entre o mundo real e o sujeito, isto é, um vínculo indissociável entre o mundo objetivo e a subjetividade do sujeito que não pode ser traduzido em números. A interpretação dos fenômenos e a atribuição de significados são

		básicas no processo de pesquisa qualitativa. Não requer o uso de métodos e técnicas estatísticas. O ambiente natural é a fonte direta para coleta de dados e o pesquisador é o instrumento-chave. É descritiva. Os pesquisadores tendem a analisar seus dados indutivamente. O processo e seu significado são os focos principais da abordagem.
Objetivos	Exploratória	Visa proporcionar maior familiaridade com o problema com vistas a torná-lo explícito ou a construir hipóteses. Envolve levantamento bibliográfico; entrevistas com pessoas que tiveram experiências práticas com o problema pesquisado; análise de exemplos que estimulem a compreensão. Assume, em geral, as formas de Pesquisas Bibliográficas e Estudos de Caso.
	Descritiva	Visa descrever as características de determinada população ou fenômeno ou o estabelecimento de relações entre variáveis. Envolve o uso de técnicas padronizadas de coleta de dados: questionário e observação sistemática. Assume, em geral, a forma de Levantamento.
	Explicativa	Visa identificar os fatores que determinam ou contribuem para a ocorrência dos fenômenos. Aprofunda o conhecimento da realidade porque explica a razão, o “porquê” das coisas. Quando realizada nas ciências naturais, requer o uso do método experimental, e nas ciências sociais requer o uso do método observacional. Assume, em geral, as formas de Pesquisa Experimental e Pesquisa Expost-facto.
Procedimentos técnicos	Pesquisa bibliográfica	Quando elaborada a partir de material já publicado, constituído principalmente de livros, artigos de periódicos e atualmente com material disponibilizado na Internet.
	Pesquisa documental	Quando elaborada a partir de materiais que não receberam tratamento analítico. Exemplos são relatórios técnicos de organizações representativas de classes e sindicatos de trabalhadores ou patronais, e ainda de organismos e consultorias nacionais e internacionais.

Pesquisa Experimental	Quando se determina um objeto de estudo, selecionam-se as variáveis que seriam capazes de influenciá-lo, definem-se as formas de controle e de observação dos efeitos que a variável produz no objeto. Normalmente o experimento é realizado em ambiente controlado.
Levantamento	Quando a pesquisa envolve a interrogação direta das pessoas cujo comportamento se deseja conhecer.
Estudo de caso	Quando envolve o estudo profundo e exaustivo de um ou poucos objetos de maneira que se permita o seu amplo e detalhado conhecimento.
Pesquisa Expost-Facto	Quando o “experimento” se realiza depois dos fatos.
Pesquisa-Ação	Quando concebida e realizada em estreita associação com uma ação ou com a resolução de um problema coletivo. Os pesquisadores e participantes representativos da situação ou do problema estão envolvidos de modo cooperativo ou participativo para a ação determinada.
Pesquisa Participante	Quando se desenvolve a partir da interação entre pesquisadores e membros das situações investigadas podendo ou não estar relacionada com uma ação específica.

**Fonte: SILVA e MENEZES, 2001 (Adaptado).**

Dessa forma, quanto à natureza, o atual estudo é aplicado, haja vista que a pesquisa visa gerar conhecimentos sobre a aplicação prática do uso de inteligência artificial para controle de qualidade em sistemas de montagem. Quanto aos objetivos, o estudo é exploratório, uma vez que busca avaliar diferentes formas de realizar a aplicação de sistemas inteligentes para avaliação da qualidade em linhas de montagem e qual será a forma ótima de aplicação a nível laboratorial. E, para uma perspectiva de procedimentos técnicos realizados, a pesquisa será do tipo experimental uma vez que serão observadas quais variáveis influenciam a aplicação do objeto de estudo e como é possível controlar determinadas variações e será realizado um experimento em laboratório.

## 2.2. Metodologia

### 2.2.1. Resumo

De forma geral, o trabalho foi desenvolvido em etapas conforme demonstra a Figura 2.



**Figura 2** - Resumo das etapas da metodologia

A primeira etapa, que corresponde ao mapeamento do processo de montagem do protótipo do caminhão foi realizada por outra colega do grupo de pesquisa e publicada no trabalho “Explorando o uso do BPMN para mapear a implementação de inteligência artificial e realidade aumentada em linhas de montagem: um estudo do processo de montagem do Truck” (LÚCIA et al., 2023).

Além dessas, aconteceram etapas de apoio ao desenvolvimento deste estudo, por meio do entendimento do projeto AuQua como um todo. Essas etapas foram a participação em reuniões com toda a equipe do projeto, sejam eles pesquisadores alemães ou brasileiros, da Universidade de Brasília ou da Universidade de São Paulo, a participação em visita técnica para entendimento das possibilidades e do ambiente real de aplicação do projeto AuQua em produção.

### 2.2.2. Softwares

Para o desenvolvimento do projeto, foram utilizados os Softwares, linguagem de programação e bibliotecas: Bizagi Modeler®, Microsoft Excel®, Python®, Seaborn®, biblioteca de visualização de dados, Matplotlib®, biblioteca de visualização de dados, TensorFlow®, framework de desenvolvimento de inteligência artificial, Keras®, framework de desenvolvimento de inteligência artificial, Networkx®, biblioteca para escrita de grafos, Pandas®, biblioteca de manipulação e análise de dados, e Os® para Python, biblioteca para manipulação do sistema operacional, como criação e movimentação de diretórios.

### 2.2.3. Desenvolvimento do grafo

Para a construção da estrutura de grafo representante do processo de montagem primeiro foi realizada uma listagem de todas as peças participantes do processo de montagem e a extração de cada tarefa do processo para uma tabela escrita no Excel®. A partir da tabela de atividades, foi possível extrair as classificações das tarefas envolvendo cada peça e as relações entre as peças.

A partir do relacionamento entre as peças, foi possível determinar quais subconjuntos parciais são montados durante o processo de montagem. Subconjunto é a união, por meio da montagem, de duas ou mais peças. O entendimento dos subconjuntos foi essencial para construir os estados do grafo, já o entendimento das atividades é importante para construir o relacionamento entre cada um dos estados formadores do grafo.

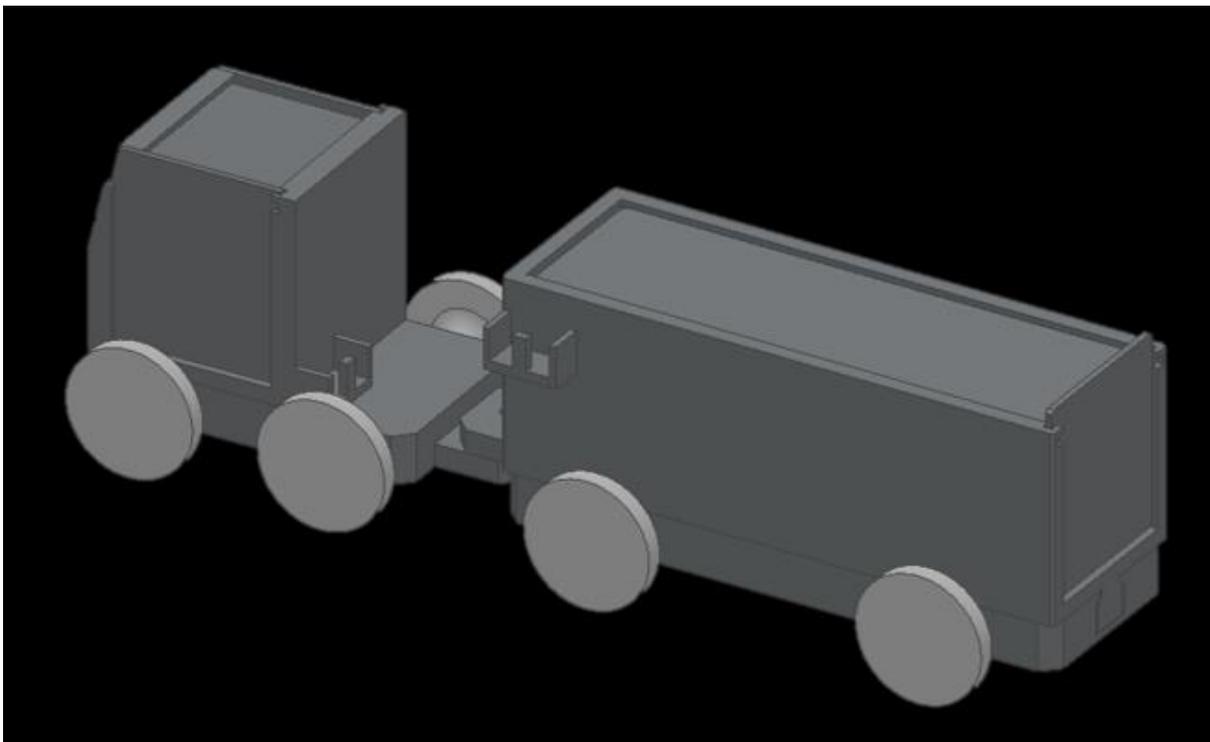
Para a construção do grafo, primeiro foi determinado o que iria compor o nó desse grafo, isto é, o estado da montagem. Foi definida a composição do estado pelo subconjunto montado naquele ponto da montagem, todos os subconjuntos passados, isto é, todos os subconjuntos que já foram montados durante o processo, estes sendo ou não participantes do subconjunto atual, todos os subconjuntos que compõem o subconjunto atual e todas as peças que compõem o subconjunto atual.

Para as arestas, determinou-se que sua composição teria a tarefa que leva o sistema de um estado 1 para um estado 2, qual o agente desta tarefa e quantas repetições são necessárias dessa tarefa para levar o sistema de um estado 1 para um estado 2.

Com essas informações, o grafo foi construído utilizando um programa em Python® para realizar o relacionamento entre cada um dos nós com as respectivas arestas que os ligariam com o apoio da biblioteca Networkx®

#### 2.2.4. Construção do conjunto de dados

Além do Grafo, o presente trabalho tem por objetivo realizar o treinamento de um modelo inteligente de classificação de objetos como uma prova de conceito. Para realizar esse treinamento, é necessário criar um conjunto de dados com imagens das peças que compõem o objeto que o sistema irá montar. O objeto escolhido é o segundo protótipo do AuQua, um caminhão feito por meio de manufatura aditiva (Figura 3).



**Figura 3** - Imagem do modelo CAD do protótipo do caminhão do projeto AuQua

Os dados disponíveis com informações sobre as partes do caminhão, necessárias para o treinamento do modelo, estão dispostas em modelos CAD como o da Figura 3. O primeiro passo para a criação de um conjunto de dados de treinamento é a adequação do tipo de dado para o mais próximo do modelo aplicado em ambiente real, para que o sistema aprenda de acordo com dados que ele irá enxergar em um ambiente aplicável.

Portanto, o primeiro passo para a construção de um conjunto de dados de treinamento foi a conversão das peças em modelos CAD para imagens bidimensionais. Isso foi realizado por meio de um script escrito em Python® que abriu os arquivos e realizou a rotação de todas as peças em ângulos aleatórios. A aleatoriedade dos ângulos foi feita por meio da biblioteca Random® que gera números pseudoaleatórios dentro de limites definidos em código. Como o

problema lida com ângulos, estes limites foram definidos entre  $-180^\circ$  e  $180^\circ$  nos três eixos de rotação (x, y e z) possíveis para aplicar os ângulos de rotações.

Além da geração das imagens em rotações diferentes, estas foram cortadas para gerar a sensação de aproximação ou afastamento da peça. Dessa forma, criando a sensação de “zoom” nas imagens das peças. Os cortes foram realizados em posições aleatórias das imagens. Para aplicar esse tratamento às imagens, foram gerados quatro números aleatórios a serem aplicados em cada um dos dois eixos da imagem bidimensional (x e y) como pontos de início e fim do corte em cada eixo. Esses cortes foram aplicados em cada uma das imagens geradas pelas rotações dos modelos CAD.

Em uma parte intermediária da geração do conjunto de dados, foi realizada a limpeza das imagens completamente pretas ou brancas, correspondentes à ausência ou presença completa de peças no espaço visto pela imagem. Como essas duas possibilidades não entregam valor de treinamento ao modelo de inteligência artificial, todas as imagens dentro dessas condições foram removidas do conjunto de dados.

Por fim, foi adicionado ruído às imagens por meio da adição de planos de fundo com colorações e formas diferentes nas imagens. Estes foram aplicados em cada uma das imagens por meio da substituição dos pixels pretos das imagens, correspondentes ao espaço vazio do modelo CAD, ou seja, ausência de peça, por possíveis planos de fundo pré-selecionados. Essa seleção gerou em 4 possibilidades e, para este, foi levado em consideração a incorporação de ruídos de cor e forma por meio do plano de fundo.

### 2.2.1. **Construção do modelo de classificação de imagens**

O modelo de classificação de imagens foi construído com base na arquitetura Xception (CHOLLET, 2016). Isto porque este algoritmo está entre as arquiteturas consideradas estado da arte nas implementações possíveis por meio do Tensor Flow e Keras (KERAS, [s.d.]) e traz uma acurácia melhor do que arquiteturas criadas do zero.

A implementação do modelo foi realizada com algoritmo escrito em linguagem de programação Python® por meio de código que lê as imagens, as separa em conjunto de treinamento e validação e entrega essas imagens à arquitetura Xception em até 10 épocas com interrupção quando a acurácia de validação diminui com o passar das épocas evitando o estado de *overfitting* do modelo.

## 3 REVISÃO BIBLIOGRÁFICA

*Na revisão bibliográfica será apresentado os conceitos fundamentais ao desenvolvimento do presente trabalho, visando assim a melhor compreensão dos resultados obtidos.*

### 3.1. Qualidade

A definição unificada de qualidade é um desafio para os teóricos (TOLEDO et al., 2014). Existem diversas formas diferentes de definir o que é qualidade, variando com base na escola de pensamento, tipo de valor a ser produzido, bem ou serviço, e no enfoque que se dará à definição.

Com relação às escolas de pensamento, os principais pensadores da qualidade são Armand Feigenbaum, Joseph Juran, Philip Crosby, William Deming, Kaoru Ishikawa e Genichi Taguchi. Para Feigenbaum, a qualidade só pode ser garantida por meio do controle da qualidade total, o qual se trata de um sistema de integração de esforços para o desenvolvimento, manutenção e aprimoramento da qualidade dos vários grupos de uma organização (TOLEDO et al., 2014). A qualidade deve ser planejada e avaliada em todos os subsistemas de uma produção para garantir a qualidade total do sistema e, como consequência, do produto fabricado (TOLEDO et al., 2014).

Para Juran, a qualidade pode ser atingida por meio do planejamento, controle e aprimoramento da qualidade. O planejamento da qualidade é um processo que visa entender quais as necessidades dos clientes do produto que está sendo desenvolvido. O controle é a etapa na qual é definido o que será controlado, onde define-se qual medida será utilizada e quais os padrões esperados de desempenho. No aprimoramento, são definidos os objetivos e a necessidade de projetos de aprimoramento de qualidade. Enquanto o planejamento e controle são processos, o aprimoramento é um projeto (TOLEDO et al., 2014).

Crosby define qualidade como a soma das qualidades obtidas nas diversas atividades e processos da empresa, dentre elas a produção (TOLEDO et al., 2014).

Deming estrutura a importância estratégica da qualidade como um dos fatores para o aumento da competitividade de uma empresa e define o planejamento de qualidade da mesma forma que um planejamento estratégico, por meio da constância de um propósito como uma

visão corporativa e da definição de metas claras para guiar as ações de qualidade em toda a empresa mantendo todos os colaboradores cientes e atualizados das definições estratégicas de qualidade (TOLEDO et al., 2014).

Ishikawa promove o sistema japonês de gestão da qualidade no qual a qualidade deve sempre estar em primeiro lugar em uma organização e esta deve ser orientada para o cliente, de forma que todas as decisões são tomadas com base no que o cliente será mais beneficiado. Além disso, dentro da filosofia do sistema japonês de qualidade, o próximo processo é seu cliente, de forma que todos os colaboradores participem da qualidade como ações diárias e executem suas tarefas com o melhor nível de qualidade para atender aos requisitos esperados pelo próximo processo. Com isso, todos os processos trabalham no nível ótimo de qualidade gerando, ao final, um produto de nível ótimo de qualidade (TOLEDO et al., 2014).

Taguchi define a qualidade robusta, a qual se trata de um método para a melhoria da qualidade com redução de custos (TOLEDO et al., 2014). O método Taguchi busca aumentar a robustez dos produtos por meio da diminuição dos efeitos dos ruídos no seu desempenho (ROZENFELD et al., 2006).

Para o enfoque transcendental, a qualidade é uma característica nata do produto e só pode ser expressa pela existência do produto e sua história (TOLEDO et al., 2014).

Para o enfoque baseado no produto, a qualidade é uma variável precisa, mensurável e depende do conteúdo de uma ou mais características do produto. Esse enfoque pressupõe que uma qualidade mais elevada resulta em custos elevados para o produto (TOLEDO et al., 2014).

Para o enfoque baseado no usuário, entende-se que a qualidade é uma percepção do usuário do produto e, portanto, uma visão subjetiva baseada em preferências pessoais. Com esta ideia, supõe-se que os bens que melhor satisfazem os consumidores são aqueles de maior qualidade. (TOLEDO et al., 2014). Uma forma de entender como satisfazer o cliente é convertendo os requisitos do cliente, isto é, o que o cliente espera que o produto contenha, em requisitos técnicos, mensuráveis, por meio do desdobramento da função qualidade, de forma que seja possível, a partir desses requisitos, a construção do produto de forma que satisfaça o cliente (ROZENFELD et al., 2006). Além disso, é possível entender como a concorrência se comporta ao atender os requisitos do cliente com suas ofertas de produto de forma a posicionar de maneira mais estratégica e racional o novo produto no mercado (ROZENFELD et al., 2006).

O enfoque baseado na fabricação entende a qualidade como a conformidade com as especificações (TOLEDO et al., 2014). Dessa forma, ao definir as especificações técnicas a

partir dos requisitos do cliente, além de possibilitar a qualidade sob o enfoque do usuário, é possível atingir a qualidade sob o enfoque de fabricação (ROZENFELD et al., 2006). A qualidade excelente em termos do enfoque de fabricação é o “fazer certo a primeira vez”. Isto é, para esse pensamento, ao seguir as especificações e o processo definido com rigor, leva-se qualidade ao produto sem a necessidade de retrabalho ou recuperação do produto (TOLEDO et al., 2014). Problemas de qualidade passam a ser problemas de não conformidade e, portanto, quantificáveis e controláveis (TOLEDO et al., 2014).

Já o enfoque baseado no valor entende qualidade sob um viés de custos e preços (TOLEDO et al., 2014). A maior qualidade é daquele produto que apresenta o desempenho esperado em uma faixa de preço aceitável (TOLEDO et al., 2014). Dessa forma, além de atender todas as especificações do cliente e satisfazê-las, o custo ou preço, passa a compor também uma das especificações do cliente.

Para o presente estudo, será considerada a qualidade com base no enfoque baseado na fabricação, por sua característica quantificável, necessária à comunicação com um programa computacional, dentro da filosofia de William Deming para a qualidade no processo.

### **3.1.1. Qualidade no processo de montagem**

Uma linha de montagem é um conjunto finito de elementos de trabalho ou tarefas, cada uma tendo um tempo de processamento de operação e um conjunto de relações de precedência que especificam a ordem permitida das tarefas (FERNANDES; FILHO, 2019). O principal problema das linhas de montagem é o balanceamento, isto é, a atribuição de tarefas a um número ordenado de estações de trabalho (FERNANDES; FILHO, 2019). Este problema, visto sob uma ótica de qualidade, pode ser mensurado a partir da inadequação da montagem realizada com a montagem planejada para determinado produto, de forma que a eficiência da linha seja balanceada e o processo seja guiado à linha de montagem ideal.

Dessa forma, o problema da qualidade na linha de montagem pode ser avaliado com indicadores de não conformidade, isto é, indicadores que apontam o descumprimento de um requisito, no caso da montagem, à realização do processo aquém das conformidades esperadas. A utilização de métodos exatos para a solução de problemas de balanceamento é complexa em abordagens computacionais (FERNANDES; FILHO, 2019). A qualidade em processos define o caminho pelo qual a relação opera (TOLEDO et al., 2014), de forma que, um processo realizado com qualidade é aquele no qual o final foi planejado anteriormente.

O controle de qualidade na linha de montagem conta com a verificação e medida de todas as partes e materiais entrantes no processo, com o cumprimento das etapas de montagem e com a testagem funcional do produto montado. Dessa forma, a garantia da qualidade nessas três etapas garante a confiabilidade geral do produto (TEALE, 1987).

Conferir a entrada das partes da montagem representa um desafio ao rejeito de materiais o que leva a um aumento da tolerância a não conformidades. Com isso, uma minoria de partes é rejeitada ao processo de montagem, no geral, aquelas que não podem ser montadas de maneira automática (TEALE, 1987). Outro problema à entrada de partes é a entrada de “não-partes”, isto é, partes incompletas, que tem perda total de função geradas por inconformidades no seu processo de fabricação (TEALE, 1987).

Após a conferência de todas as partes integrantes do produto, a montagem deve prosseguir para o início do processo em conformidade com o processo planejado (TEALE, 1987). A qualidade da montagem se dá se todas as etapas do processo planejado estão sendo cumpridas no processo realizado (TEALE, 1987), caso contrário, são necessárias medidas de correção para garantir a qualidade do processo (ROZENFELD et al., 2006; TOLEDO et al., 2014).

Por fim, o produto montado é testado (TEALE, 1987). Caso exista alguma não conformidade entre as funcionalidades do produto e as especificações definidas no projeto de desenvolvimento de produto (ROZENFELD et al., 2006), existe uma falha de produto (TEALE, 1987; TOLEDO et al., 2014).

### **3.1.2. Controle de qualidade na indústria 4.0**

Indústria 4.0 é um termo alemão para designar a transformação digital da manufatura (KLINGENBERG, 2017). Isto é, um termo que denota a aplicação integrada de tecnologias em linhas de manufatura, tecnologias essas que visam otimizar processos e melhorar a entrega dos produtos realizada. A Indústria 4.0 envolve uma mudança estrutural da base tecnológica da manufatura, permitindo flexibilidade em termos de especificações do produto, qualidade, design, volume de produção, tempo de produção (ORTT; STOLWIJK; PUNTER, 2020). Além disso, a Indústria 4.0 também permite um uso mais eficiente de recursos e otimização de custos, o que também é uma das definições da qualidade baseado no enfoque de valor (TOLEDO et al., 2014).

O enfoque na indústria 4.0 aqui trabalhado é o de habilitadores tecnológicos, que agregados aos habilitadores organizacionais e à maturidade de processos, permite a digitalização da manufatura como um todo (FELIPPES et al., 2022). O principal habilitador tecnológico da quarta revolução industrial são sistemas cyber físicos – CPS – isto é, a interface entre sistemas físicos e virtuais de forma que tudo o

que acontece no mundo real impacta o sistema virtual e vice-versa (KLINGENBERG, 2017). Ainda, a indústria 4.0 tem como característica o aspecto cumulativo das tecnologias aplicadas na manufatura, tecnologias essas que têm impactos interessantes na melhoria dos sistemas produtivos e de montagem com incremento gradual da qualidade a partir da interação entre sistemas e humanos (KLINGENBERG, 2017).

Independente do setor, a utilização de tecnologias integradas na manufatura implica em mudanças na forma de realizar as tarefas em uma indústria. Essas mudanças podem ser positivas ou negativas em diferentes aspectos, incluindo padrões de qualidade (ORTT; STOLWIJK; PUNTER, 2020). Entretanto, o estudo *“Implementing Industry 4.0: assessing the current state”* (ORTT; STOLWIJK; PUNTER, 2020) avaliou os impactos da indústria 4.0 na estrutura da gestão de cadeia de suprimentos e identificou que, entre os claros benefícios da implementação da indústria 4.0 estão o aumento da flexibilidade, de padrões de qualidade, de níveis de eficiência e produtividade (ORTT; STOLWIJK; PUNTER, 2020). Todos esses aspectos podem ser englobados como integrantes da qualidade total de um produto e de sua linha de montagem e fabricação a depender do enfoque utilizado para a avaliação destes. Sob o enfoque do usuário, ter um produto presente no mercado em diferentes versões, resultado da maior flexibilidade, pode estar em acordo com os requisitos traçados pelo cliente o que aumenta a satisfação deste gerando um maior nível de qualidade (ROZENFELD et al., 2006; TOLEDO et al., 2014). Sob o enfoque de valor, a maior produtividade e eficiência geram maior qualidade do produto ao passo que o aumento desses pontos garante a produção com menores custos de produção (TOLEDO et al., 2014).

### **3.2. Inteligência artificial**

Entre as definições clássicas para “inteligência artificial” estão o uso do computador para executar raciocínio, reconhecimento de padrões, aprendizado ou outras formas de inferência (LUGER, 2009); um foco em problemas que não respondem a soluções algorítmicas; interesse na solução de problemas utilizando informação inexata, faltante ou insuficiente definida; raciocínio que utiliza as características qualitativas significativas de uma situação; tentativa de tratar questões que envolvem tanto significado semântico de forma sintática; respostas que não são nem exatas nem ótimas mas que são suficientes em um certo sentido; uso de grandes quantidades de conhecimento específico de um domínio para resolver problemas; uso de meta-conhecimento para produzir um controle mais sofisticado sobre as estratégias de resolução de problemas (LUGER, 2009).

O “uso do computador para executar raciocínio, reconhecimento de padrões, aprendizado ou outras formas de inferência” está ligado ao conceito de automação, na qual atividades repetitivas de raciocínio, com o reconhecimento de padrões podem ser delegados a um computador de forma que otimize o uso do tempo de recursos humanos. Dado um conjunto de dados suficientemente grande, processadores rápidos e um algoritmo suficientemente sofisticado, os computadores podem começar a realizar tarefas

que até então só podiam ser realizadas por seres humanos (DATA SCIENCE ACADEMY, 2022). No caso da inteligência artificial, dependendo da forma como o algoritmo é construído, além da automação, o computador passa a aprender a atividade, de forma que sua tarefa seja otimizada ao longo de sua execução (DATA SCIENCE ACADEMY, 2022; MITCHELL, 1997).

Existem técnicas variadas de inteligência artificial, como a algoritmos de aprendizado de máquina clássicos, tais quais árvore de decisão, redes neurais, aprendizado bayesiano, algoritmos genéticos, Q-learning (MITCHELL, 1997). Todos esses algoritmos, performam operações matemáticas em conjuntos de dados e podem, com isso, resolver problemas, como regressão, classificação ou reconhecimento de padrões (DATA SCIENCE ACADEMY, 2022; GÉRON, 2022; MITCHELL, 1997).

Um algoritmo de aprendizagem de máquina permite, ao computador, melhorar automaticamente por meio da experiência (MITCHELL, 1997), isso é, por meio da realização de operações matemáticas em dados apresentados para o computador, este entrega resultados com base nas operações realizadas e, a partir destes, realiza ajustes buscando melhorias na entrega de respostas, a esse processo dá-se o nome de otimização (DATA SCIENCE ACADEMY, 2022).

A otimização de um algoritmo de inteligência artificial pode ser observada por meio do aumento da acurácia a cada iteração que este realiza sobre o problema, de forma que, a cada vez que o algoritmo processa determinado conjunto de dados, este altera os parâmetros de sua arquitetura e entrega resultados cada vez mais coerentes com o que se espera, aumentando, assim, a acurácia (DATA SCIENCE ACADEMY, 2022).

Trazendo exemplos da aplicação de inteligência artificial, existem os algoritmos de árvore de decisão. Esse método corresponde a uma aproximação de funções de valor alvo discreto, um conjunto de regras do tipo “se, então” representados em forma de uma árvore com suas etapas de decisão e os grupos formados por estes (Figura 4), de forma a permitir uma legibilidade do algoritmo (MITCHELL, 1997).

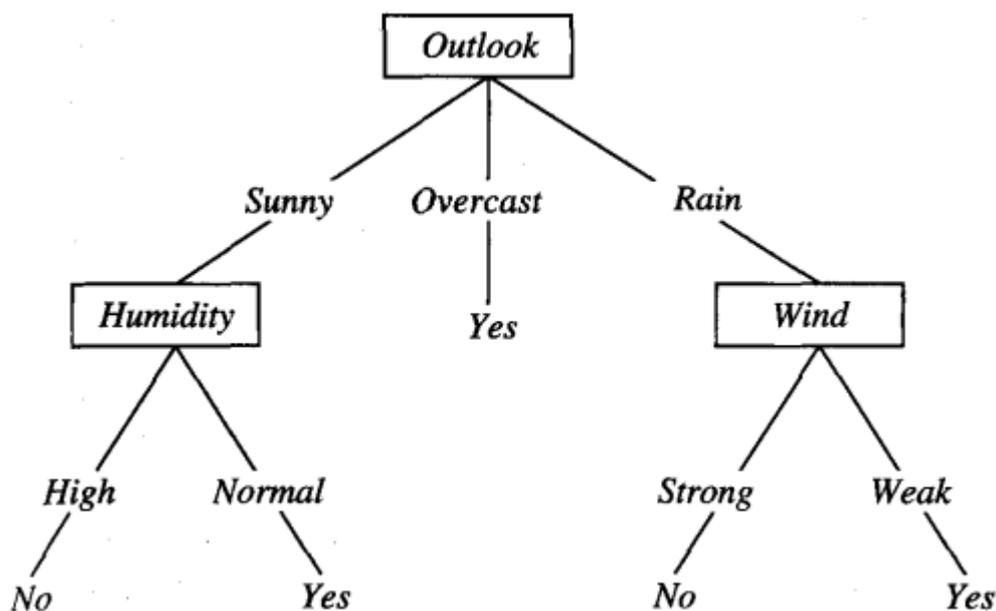
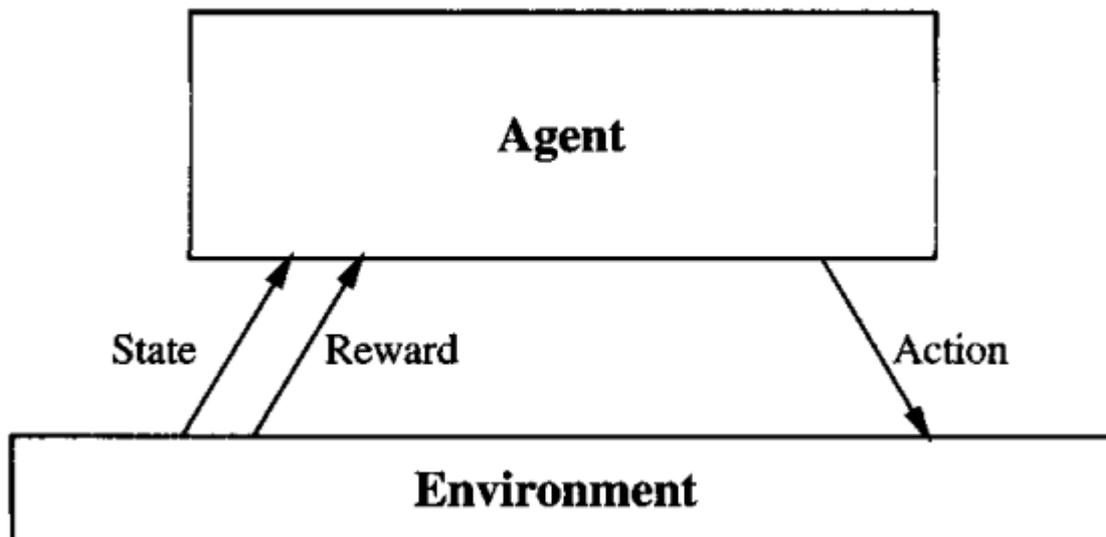


Figura 4 - Árvore de decisão

Fonte: Mitchell, T. 1997

Uma árvore de decisão classifica dados organizando estes em grupos criando uma estrutura de árvore desde a raiz (conjunto de dados completo) até um nó folha (nó final de classificação) (MITCHELL, 1997). Para garantir que os grupos estão sendo bem definidos pelo algoritmo, em cada nó, são avaliadas medidas de homogeneidade, isso é, quanto a classificação de um grupo de indivíduos representa bem a totalidade do grupo ou quão semelhantes são os indivíduos de um mesmo grupo em uma árvore de decisão. As formas de calcular a homogeneidade em uma árvore de decisão podem variar conforme o tipo de problema sendo estudado, de forma que o cálculo escolhido melhor se adapte às características do problema endereçado (DAUDA, 2022).

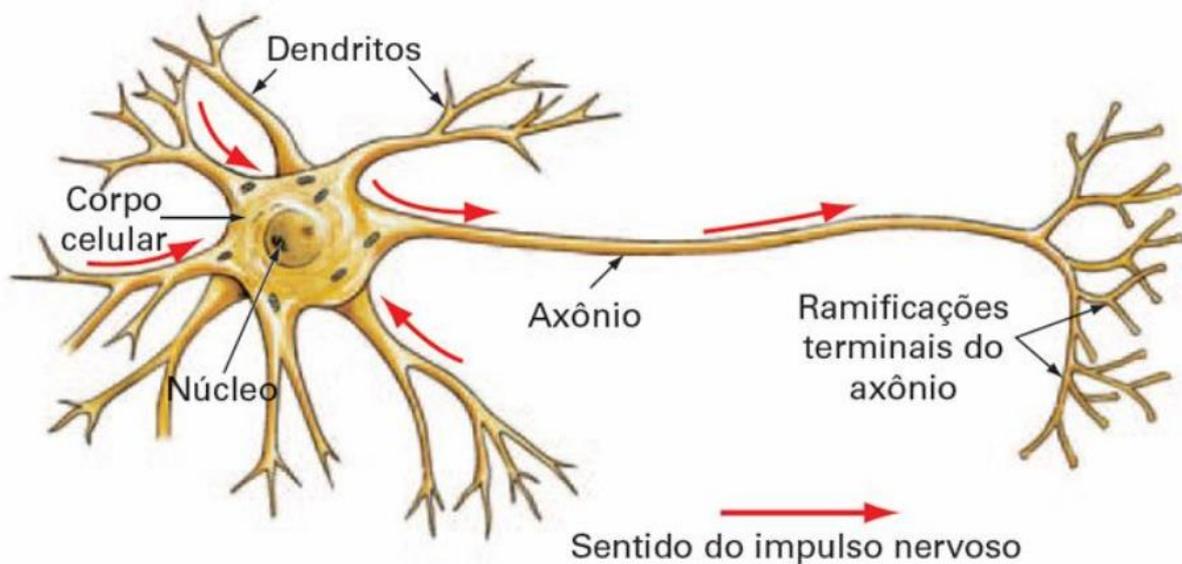
Além das árvores de decisão, existem outros algoritmos frequentemente utilizados, agrupados em uma categoria chamada aprendizagem por reforço (MITCHELL, 1997). Esse tipo de algoritmo endereça questões sobre como agentes autônomos podem avaliar e tomar ações sobre determinado ambiente e aprende a tomar melhores ações para alcançar metas definidas. De forma geral, um algoritmo de aprendizagem por reforço pode ser ilustrado como na Figura 5.



**Figura 5** - Representação de um algoritmo de aprendizagem por reforço genérico

Nesse tipo de algoritmo, o estado do ambiente é analisado pelo agente que, por sua vez, realiza uma ação e, baseado no novo estado do ambiente, recebe uma recompensa que age como modulação da função de aprendizado (MITCHELL, 1997). Esse tipo de algoritmo pode ser especialmente útil quando endereçado um problema de otimização porque, dada suas características, apresenta menores chances de a solução do problema ficar limitada a um máximo (ou mínimo, a depender do problema) local, possibilitando seu uso para buscar máximos globais, permitindo a melhora dos resultados em problemas de otimização (PACK KAEHLING et al., 1996).

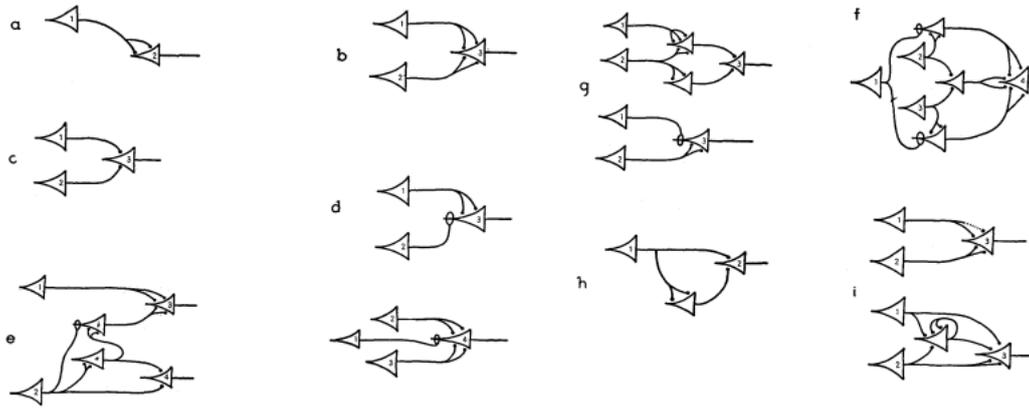
Outro exemplo de algoritmo de inteligência artificial, são as redes neurais, isto é, uma arquitetura computacional, baseada em uma metáfora biológica, estruturada a partir da combinação de neurônios matemáticos (LUGER, 2009). O funcionamento do neurônio matemático foi proposto com base na propagação de um impulso nervoso em um neurônio biológico (Figura 6), da mesma forma que um impulso nervoso só é propagado para um próximo neurônio caso este atinja um limiar de ativação, um neurônio matemático (Figura 8) só transmite a informação adiante caso a função de ativação deste atinja seu limiar.



**Figura 6** - Representação da propagação de um impulso nervoso em um neurônio biológico

**Fonte:** Data Science Academy, 2022

O modelo mais aceito de neurônio matemático foi proposto em 1943 por Warren McCulloch e Walter Pitts (Figura 7), estudo que propõe o fluxo lógico da atividade nervosa por meio de definições matemáticas (MCCULLOCH; PITTS, 1943). Neste trabalho, os autores explicam matematicamente como funciona o impulso “tudo ou nada”, que explica a atividade basal de um neurônio na propagação do impulso nervoso, no qual, se o impulso atinge um limiar de ativação, isto é, uma quantidade suficientemente grande de sinapses ativadas por um impulso, em um quarto de milissegundo, este é passado a frente, caso contrário, o impulso é perdido sem gerar “acúmulo” de excitação nervosa (MCCULLOCH; PITTS, 1943). Dessa forma, o modelo tem uma atividade binária, tanto para os sinais quanto para as saídas do neurônio, de acordo com esse modelo, um neurônio ativa ou não o próximo (DATA SCIENCE ACADEMY, 2022; MCCULLOCH; PITTS, 1943).

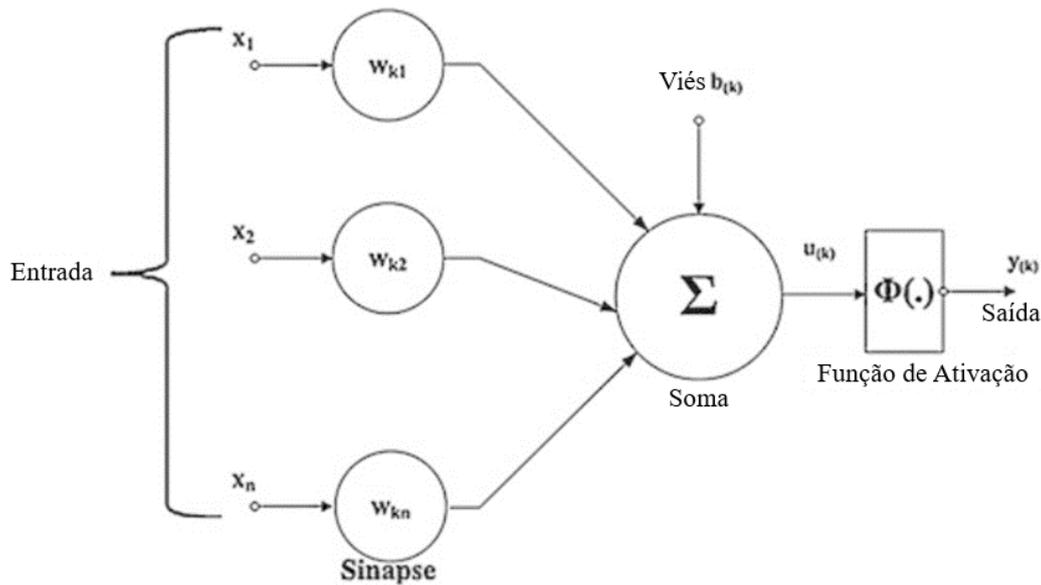


**a**  $N_2(t) \equiv N_1(t - 1)$   
**b**  $N_3(t) \equiv N_1(t - 1) \vee N_2(t - 1)$   
**c**  $N_3(t) \equiv N_1(t - 1) \cdot N_2(t - 1)$   
**d**  $N_3(t) \equiv N_1(t - 1) \cdot \infty N_2(t - 1)$   
**e**  $N_3(t) \equiv N_1(t - 1) \cdot \vee \cdot N_2(t - 3) \cdot \infty N_2(t - 2)$   
 $N_4(t) \equiv N_2(t - 2) \cdot N_2(t - 1)$   
**f**  $N_4(t) \equiv \infty N_1(t - 1) \cdot N_2(t - 1) \vee N_3(t - 1) \cdot \vee \cdot N_1(t - 1) \cdot N_2(t - 1) \cdot N_3(t - 1)$   
 $N_4(t) \equiv \infty N_1(t - 2) \cdot N_2(t - 2) \vee N_3(t - 2) \cdot \vee \cdot N_1(t - 2) \cdot N_2(t - 2) \cdot N_3(t - 2)$   
**g**  $N_3(t) \equiv N_2(t - 2) \cdot \infty N_1(t - 3)$   
**h**  $N_2(t) \equiv N_1(t - 1) \cdot N_1(t - 2)$   
**i**  $N_3(t) \equiv N_2(t - 1) \cdot \vee \cdot N_1(t - 1) \cdot (Ex) t - 1 \cdot N_1(x) \cdot N_2(x)$

**Figura 7** - Modelo de neurônio matemático e equações correspondentes de McCulloch e Pitts

Fonte: McCulloch e Pitts, 1943 (Adaptado)

De forma geral, o modelo de McCulloch e Pitts pode ser simplificado de maneira que explica satisfatoriamente o funcionamento do modelo proposto de maneira mais sintetizada (Figura 8). Nesta representação,  $x$  representam os sinais de entrada,  $w$  representam os pesos sinápticos,  $\Sigma$  é o combinador linear,  $b$  é o limiar de ativação,  $u$  é o potencial de ativação,  $\phi$  é a função de ativação e  $y$  é o sinal de saída. Onde os sinais de entrada são sinais externos normalizados, ou seja, os dados que o modelo se propõe a analisar. Os pesos sinápticos são os valores que ponderam os sinais de cada entrada da rede neural os quais são aprendidos durante o período de treinamento da rede. O combinador linear agrega todos os sinais de entrada ponderados a fim de produzir um potencial de ativação. O limiar de ativação especifica o patamar apropriado para que o resultado produzido pelo combinador possa gerar um disparo na função de ativação. O potencial de ativação é o resultado obtido pela diferença entre o limiar de ativação e o valor produzido pelo combinador linear. A função de ativação a qual serve para limitar a saída de um neurônio a um intervalo de valores, de forma que a saída do neurônio também seja normalizada dentro de uma faixa conhecida de valores. E o sinal de saída é o valor final do neurônio o qual pode ser o valor final da rede ou pode ser utilizado como sinal de entrada para neurônios subsequentes em uma mesma rede (DATA SCIENCE ACADEMY, 2022).



**Figura 8** - Representação simplificada de um neurônio matemático

**Fonte:** Data Science Academy, 2022

Além desses exemplos, existem outras possibilidades de aplicação que não serão comentadas mais a fundo neste trabalho como algoritmos genéticos, que também trazem conceitos da biologia para aplicação matemática em outros tipos de problemas (MIRJALILI, 2019), e outros tipos de aprendizado como o Bayesiano que utiliza métodos probabilísticos para conduzir o aprendizado em um problema computacional (MITCHELL, 1997).

Em acordo com os objetivos e com a justificativa para o desenvolvimento do projeto, o conceito de inteligência artificial adotado neste estudo será “uso do computador para executar raciocínio, reconhecimento de padrões, aprendizado ou outras formas de inferência”.

### 3.2.1. Sistemas de inteligência artificial para o controle de qualidade

O controle de qualidade na montagem passa por etapas bem definidas e descritas (TEALE, 1987). É comum que sejam utilizados métodos estatísticos, isto é, com amostragem, para garantir a qualidade das peças entrantes no processo de montagem, a adoção do processo previsto e padronizado no processo real e a funcionalidade prevista do produto montado (TEALE, 1987). Entretanto, pode acontecer em uma determinada situação prática que a porcentagem de produtos defeituosos seja reduzida o suficiente para passar despercebido entre os métodos tradicionais de medição da qualidade (TOLEDO et al., 2014).

Nesses casos, pode ser interessante a entrada de indicadores mais complexos para garantir a qualidade do processo (TOLEDO et al., 2014) ou a adoção de técnicas de inteligência artificial para realizar uma análise completa e eficiente dos produtos fabricados e montados. O uso de inteligência artificial para atividades de controle de qualidade tem sido avaliado por trazer uma maior otimização para tarefas de controle de qualidade (VANDEWINCKELE et al., 2020). Otimização essa que possibilita a análise de uma maior quantidade de indivíduos, tornando análise da linha de montagem em tempo real uma alternativa viável para o controle de qualidade, o que aumenta a confiabilidade dos produtos gerados (TEALE, 1987).

A principal vantagem do uso de inteligência artificial em uma linha de montagem para o controle de qualidade é a otimização do processo (VANDEWINCKELE et al., 2020) o que viabiliza a análise de uma maior quantidade de indivíduos, idealmente, todos os indivíduos poderiam ser analisados. Isso torna a amostragem estatística para controle de qualidade mais próxima de um censo, o que melhoraria a confiabilidade da montagem. Realizando essa análise em tempo real, a linha de montagem não perderia performance, entretanto, teria uma melhora na qualidade do produto gerado, melhorando, assim, a eficiência do processo.

### 3.2.2. Controle de qualidade em um sistema de assistência à montagem

Um *Assembly Assistance System* – AAS – é um sistema que recebe e processa informação vinda do ambiente para apoiar a realização de atividade humana (HINRICHSEN; RIEDIGER; UNRAU, 2016). Uma das formas do controle de qualidade em uma linha de montagem é a garantia da realização das atividades de montagem em concordância com a montagem planejada (TEALE, 1987). Ao apoiar a realização da atividade humana, um AAS garante ao operador o conhecimento necessário para a realização correta da atividade, apoiando a garantia de um dos pontos de controle de qualidade em um processo de montagem (TEALE, 1987).

Em combinação com o planejamento dos métodos de trabalho, métodos AAS podem melhorar significativamente a qualidade e eficiência da montagem (HINRICHSEN; RIEDIGER; UNRAU, 2016). A qualidade pode ser verificada, nesse caso, a partir da baixa taxa de erros das tarefas realizadas (HINRICHSEN; RIEDIGER; UNRAU, 2016).

Um AAS pode ser classificado com base no tipo de suporte do sistema. Pode-se distinguir entre sistemas de suporte físico ou antropomórfico (FELIPPES et al., 2022), como robôs de carga, e sistemas de suporte informativos ou cognitivos (FELIPPES et al., 2022), como sistemas que exibem informações das próximas etapas do processo, instruindo o operador a realizá-lo da maneira prevista (HINRICHSEN; RIEDIGER; UNRAU, 2016). Ambos os tipos de sistema são

projetados para aumentar a produtividade do operador e, conseqüentemente, da linha de montagem, e aumentar a qualidade do processo por meio, principalmente, da execução correta deste (HINRICHSSEN; RIEDIGER; UNRAU, 2016), por um sistema de apoio físico ou por parte do operador.

### 3.3. Estado da arte

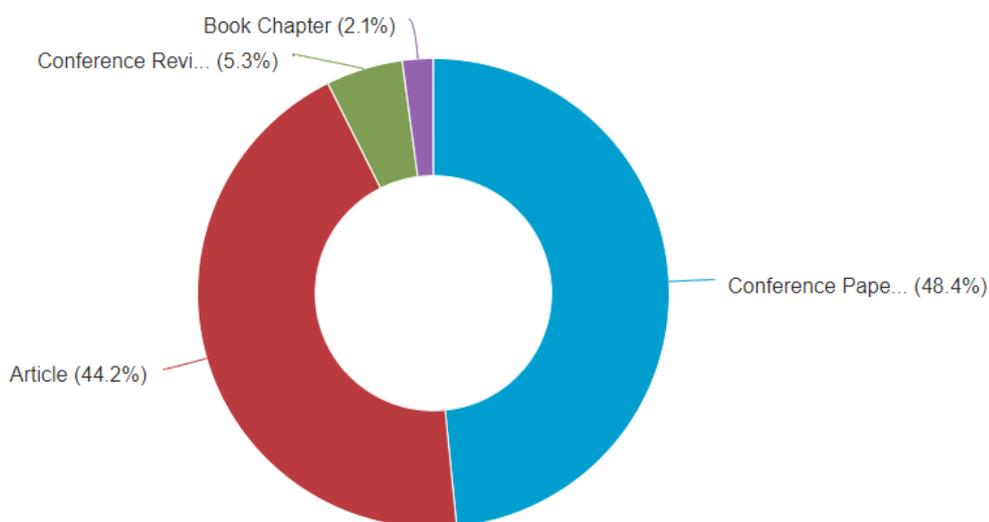
Para avaliar a literatura existente sobre a implementação de técnicas de aprendizado profundo na aferição de qualidade da montagem em processos industriais, a seguinte chave de busca foi utilizada:

TITLE-ABS-KEY ("Deep Learning" AND "industr\*\*" AND ("assembly" AND "Quality"))

Dessa forma, a busca retorna todos aqueles trabalhos onde encontram-se os termos “*Deep Learning*”, “*Industry*” e suas variações como “*Industrial*” ou “*Industry 4.0*”, “*Assembly*” e “*Quality*” no título, resumo ou palavras-chave.

Com essa busca, foram encontrados 95 trabalhos divididos em 46 trabalhos apresentados em conferências, 42 artigos publicados em revistas, 5 revisões apresentadas em conferências e 2 capítulos de livros, na proporção apresentada no **Gráfico 1**.

Documents by type



**Gráfico 1** - Proporção de trabalhos por tipo de publicação

Nesse trabalho, foram analisados apenas artigos publicados em revistas e escritos na língua inglesa. Entretanto, o artigo “*Serial Number Recognition of Ceramic Membrane Based on End-to-end Deep Learning*”(WANG, 2024) que foi encontrado na busca bibliométrica, está com data de publicação para 2024, portanto, foi removido da análise do trabalho, totalizando 37 trabalhos.

No corpo de publicações, o trabalho mais antigo encontrado foi publicado em 2017 com o título “*Reducing false detection during inspection of HDD using super resolution image processing and Deep Learning*” (IEAMSAARD; SANDNES; MUNEEAWANG, 2017). Esse trabalho estudou a detecção de falhas durante a inspeção de *Hard Disk Drives*, um componente de computadores. O trabalho utilizou redes neurais convolucionais (CNN’s) para avaliar imagens em três canais da produção de *Hard Disk Drives*.

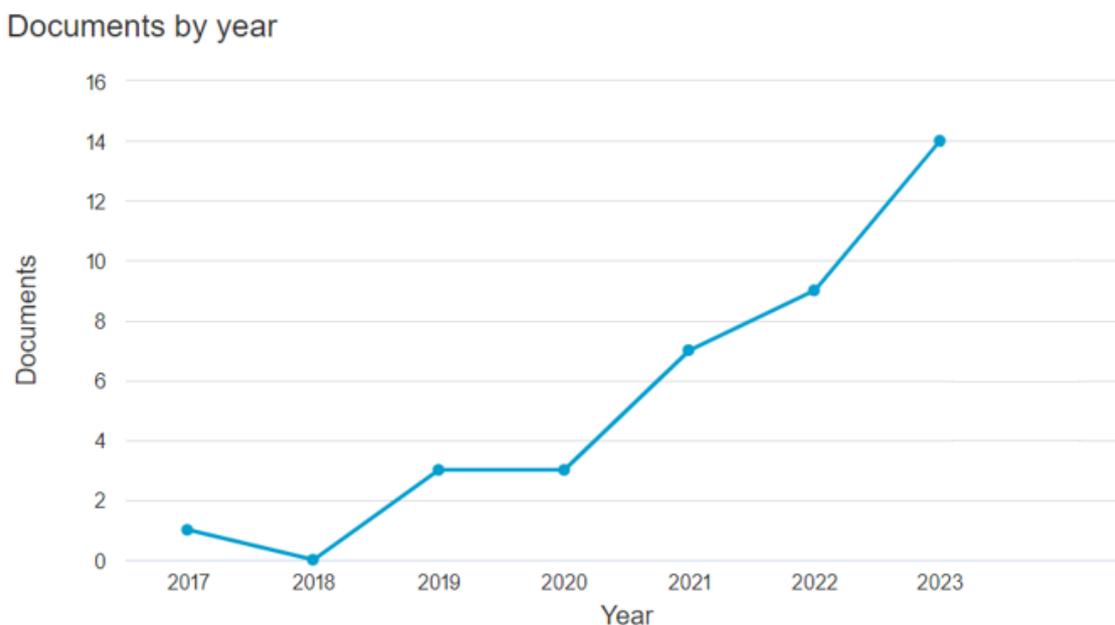


Gráfico 2 – Quantidade de publicações por ano

A partir de 2019, o número de publicações na área se tornou crescente. O ano contou com 3 artigos sobre o tema e o trabalho com maior quantidade de citações foi publicado neste ano, “*Fault Detection and Isolation in Industrial Processes Using Deep Learning Approaches*” (IQBAL et al., 2019). Este artigo traz uma abordagem de automação da detecção de falhas por meio de redes neurais artificiais. A avaliação das amostras foi realizada pelo Algoritmo 1 e discute os benefícios esperados da automação na detecção de falhas e sua comparação com métodos clássicos e contemporâneos de avaliação de defeitos.

---

**Algorithm 1: Real-Time Module Operation.**

---

```
1: Load model parameters from database.
2: Initialise  $i = 1$ ,  $MinSmp = 5$ ,  $LS = []$ 
3: while(true) do
4:    $j =$  Acquire input signals
5:    $v =$  Encode signals  $j$  into SDR
6:    $f =$  Map  $v$  into feature space
7:    $s =$  Extract state identifier for  $f$ 
8:    $LS[i] = s$     $LS =$  list of previous states
9:   if( $i < MinSmp$ ) then    $MinSmp =$  min. samples for
inference
10:    continue
11:  else
12:     $p =$  Get state prediction based on  $LS[1:i-1]$ 
13:     $g =$  Get centroid for the state  $p$ 
14:     $res = g - f$   $res =$  residual vector
15:     $good\_noGood =$  Classify  $res$ 
16:    if( $good\_noGood == True$ ) then
17:      return NoFault
18:    else
19:      return Fault
20:    end if
21:  end if
22: end while
```

---

**Algoritmo 1 - Real Time Module Operation**

(Fonte: Fault Detection and Isolation in Industrial Processes Using Deep Learning Approaches)

A detecção de falhas automatizada é interessante porque pode ser combinada com algoritmos de predição para prever comportamentos futuros da linha de montagem e, assim, prever e evitar falhas (IQBAL et al., 2019). Um dos maiores problemas, citados pelo trabalho, é a definição dos limiares para características avaliadas. Isso porque, os principais métodos de detecção de falhas até então, comparavam características com valores limiares de referência para identificar a existência ou não de defeitos em determinada montagem. Uma das formas de perpassar esse problema é a adoção do controle estatístico de processos que, entretanto, utiliza dados de determinados momentos, o trabalho utiliza a automação como uma forma de realizar um controle mais amplo da detecção de defeitos com dados em tempo real da linha de montagem o que pode levar a um processo mais fiel e controlado de detecção de falhas e identificação de padrões para prevenção de falhas.

Para avaliar a relevância global do tema, é interessante validar como se dá o perfil de publicações por país. A maior quantidade de publicações concentrada em um país está na China com 16 dos 37 trabalhos analisados. Ainda, considerando os artigos publicados em chinês, são 20 artigos sobre o tema.

### Documents by country or territory

Compare the document counts for up to 15 countries/territories.

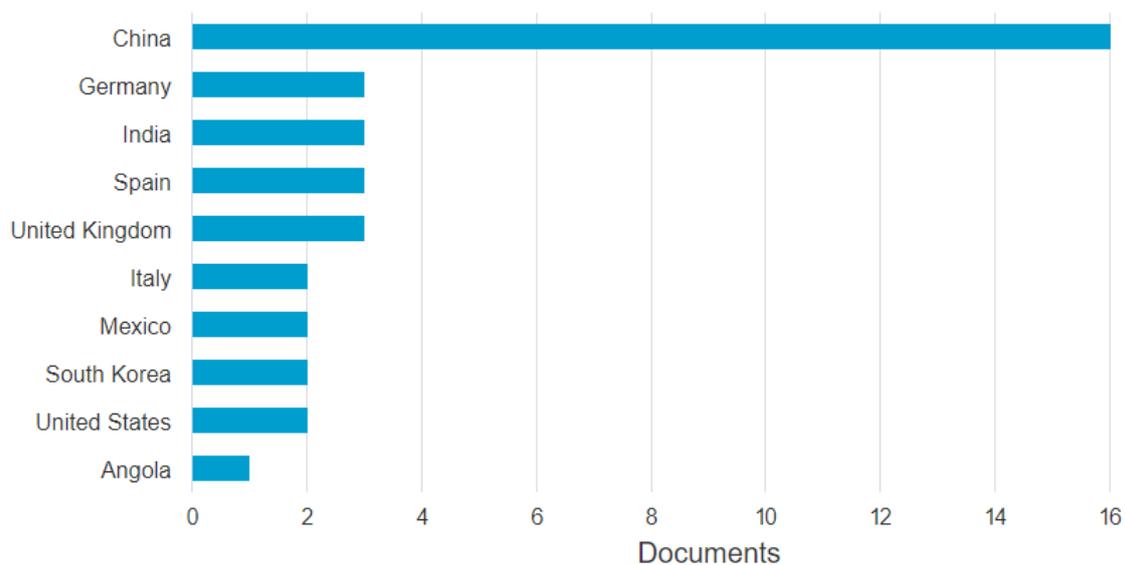


Gráfico 3 – Quantidade de publicações por país

O trabalho chinês com a maior quantidade de citações é o artigo “*Stud Pose Detection Based on Photometric Stereo and Lightweight YOLOv4*” (ZHANG; WANG, 2022). O trabalho trata do desenvolvimento e implementação de um algoritmo *you only look once (YOLO)* simplificado para a avaliação do posicionamento de pinos na montagem de automóveis.

O algoritmo *YOLO* é uma arquitetura utilizada para a detecção e rastreamento em tempo real de vários objetos, gerando coordenadas para cada objeto (REDMON et al., 2015), de forma que a incidência de um objeto em um vídeo não será processada mais de uma vez o que ajuda na avaliação de métricas, como contagem, ao passo que o algoritmo diminui a replicação de detecções. A versão 4 – *YOLOv4* – é otimizada para velocidade e acurácia na detecção de objetos (BOCHKOVSKIY; WANG; LIAO, 2020), nesse caso, o posicionamento dos pinos soldados.

Pinos soldados são importantes partes de peças de automotivas e falhas no posicionamento destes durante o processo de soldagem pode gerar falhas no processo de montagem de

automóveis (ZHANG; WANG, 2022). Durante o desenvolvimento do trabalho, entretanto, o grupo encontrou problemas na detecção do posicionamento dos pinos utilizando imagens comuns e passaram a testar o algoritmo em fotometrias estéreas que fornecem, também, a profundidade de objetos melhorando a performance do algoritmo.

O trabalho de maior relevância, de acordo com a base de dados Scopus (acesso via Periódicos Capes – Acesso CAFE Universidade de Brasília – é o artigo espanhol “*Deep Learning-based visual control assistant for assembly in Industry 4.0*” (ZAMORA-HERNÁNDEZ et al., 2021). Para a base de dados Scopus, a relevância é medida por meio do *H index* dos autores dos trabalhos. Esse trabalho propõe uma abordagem para avaliar as atividades realizadas por operadores durante o processo de montagem em uma célula produtiva, buscando prevenir falhas. O trabalho se propõe a detectar e reduzir erros na execução de instruções de montagem, desperdício de materiais, uso incorreto de ferramentas e a curva de aprendizado da montagem levando a uma redução de falhas no produto. Neste trabalho, algoritmos como *YOLO* e redes neurais convolucionais de rápidas regiões (*Faster R-CNN*) foram treinados para identificar quais ferramentas são utilizadas no processo de montagem, permitem a identificação das peças montadas e interpretam a atividade que o usuário está executando (ZAMORA-HERNÁNDEZ et al., 2021).

A prevenção de falhas é o processo de melhorar a qualidade e a produtividade prevenindo a inserção de defeitos em um produto (MAYS et al., 1990). Ao utilizar automação por meio da inteligência artificial para monitoramento focado em prevenção de falhas, o sistema proposto avalia diretamente a ação do operador o que pode promover um aumento na produtividade do operador, redução no desperdício e no custo da produção com falhas e desperdício de material, melhora na produtividade da indústria e diminuição do tempo de entrega dos produtos para clientes (MAYS et al., 1990).

Dentre os trabalhos com a maior quantidade de citações e relevância destacam-se dois “*An optimized Deep Learning approach to detect and classify defective tiles in production line for efficient industrial quality control*”(KOVILPILLAI; JAYANTHY, 2023) e “*Nuts&bolts: YOLO-v5 and image processing based component identification system*”(MUSHTAQ et al., 2023a) demonstrando que a aplicação de técnicas de *Deep Learning* para a avaliação da qualidade no processo de montagem não está restrita a determinado tipo de indústria, podendo ser aplicado, além dessas, na indústria alimentícia (ZHOU et al., 2022), de computação, (IEAMSAARD; SANDNES; MUNEESAWANG, 2017), de manufatura de móveis(AUGUSTAUSKAS; LIPNICKAS; SURGAILIS, 2021), têxtil(ZHANG et al., 2020),

automotiva(ESPINOSA; PONCE; GUTIÉRREZ, 2021), aeroespacial(LU et al., 2022), eletrônica (SCHWEBIG; TUTSCH, 2020a).

De maneira geral, existem 3 principais tendências na pesquisa sobre aplicação de *Deep Learning* no processo de montagem industrial. Isso pode ser avaliado por meio do acoplamento bibliográfico, que representa trabalhos que citam referências em comum e, por utilizar referências semelhantes, podem indicar tendências para trabalhos futuros naquela área.

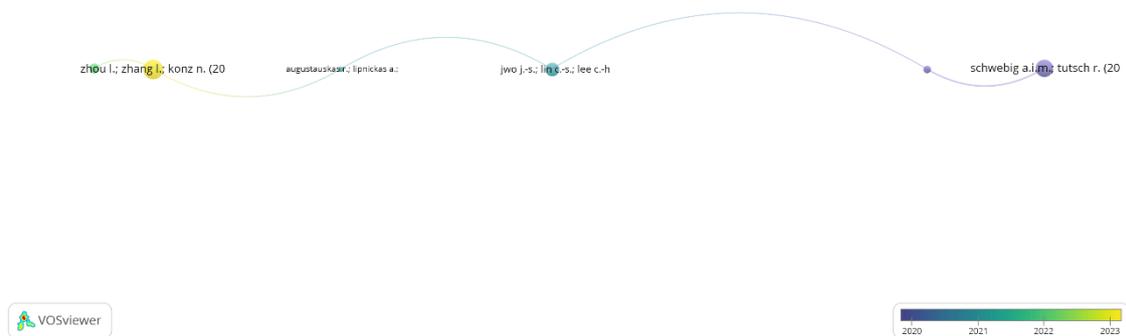
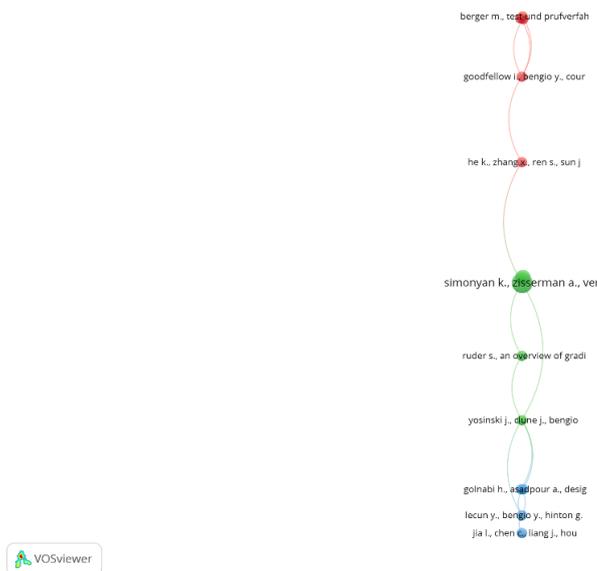


Figura 9 - Diagrama de acoplamento bibliográfico destacados por ano

As tendências possíveis indicadas pela análise dos agrupamentos (Figura 9 - Diagrama de acoplamento bibliográfico destacados por ano) são a pesquisa com redes neurais convolucionais na indústria eletrônica (SCHWEBIG; TUTSCH, 2020a, 2020b), identificação de falhas em peças naturalmente irregulares (AUGUSTAUSKAS; LIPNICKAS; SURGAILIS, 2021; JWO et al., 2021), e a automação de processo de detecção de falhas na indústria de transportes (LU et al., 2022; ZHOU; ZHANG; KONZ, 2023).

Outro indicador importante para avaliar como se encaminham as relações entre os trabalhos na área é a análise de cocitação a qual avalia quais os trabalhos mais citados em conjunto que demonstra quais as bibliografias mais comuns para a área. Trabalhos agrupados por cocitação ajudam a identificar vertentes de pesquisa dentro do tema, uma vez que trabalhos que citam um mesmo terceiro em comum tem maior chance de terem contribuições com bases semelhantes e, assim, constrói-se uma vertente de pesquisa.



**Figura 10** - Diagrama de cocitação

Apesar de serem identificados 3 grupos (Figura 10), a partir do detalhamento (Tabela 2), é possível perceber que o trabalho “*Deep residual learning for image recognition*” (HE et al., 2016) está presente nos grupos 1 e 2. Ainda, os trabalhos “*How transferable are features in deep neural networks?*” (YOSINSKI et al., 2014) e “*Gradient-based learning applied to document recognition*” (LECUN et al., 1998) do grupo 2 e “*Deep Learning*” (LECUN; BENGIO; HINTON, 2015) do grupo 3 são escritos pelos mesmos autores. Demonstrando a proximidade entre as redes de cocitação do tema.

**Tabela 2** - Referências em cocitação bibliográfica

Trabalho	Observações
<b>Grupo 1</b>	
Berger m., test-und prufverfah in der elektronikfertigung: vom arbeitsprinzip bis design-for-test-regeln, (2012)	Livro sobre teste e inspeção focado na indústria eletrônica
Goodfellow i., bengio y., 31ourville a., <i>Deep Learning</i> , (2016)	Livro sobre principais técnicas e teoria de <i>Deep Learning</i>
He k., zhang x., ren s., sun j., deep residual learning for image recognition, proceedings of the	Trabalho apresentado em conferência sobre <i>Deep</i>

ieee conference on computer vision and pattern recognition, pp. 770-778 *Learning* para reconhecimento de imagens

Muller a. c., guido s., einfuhrung in machine learning mit python: praxiswissen data science, (2017) Artigo prático sobre introdução a *machine learning* com *python*

Raschka s., mirjalili v., machine learning mit python und scikit-learn und tensorflow: das umfassende praxis-handbuch fur data science, *Deep Learning* und predictive analytics, 2, (2018) Artigo sobre introdução a *machine learning* com python e frameworks: scikit-learn e tensorflow

## Grupo 2

---

He k., zhang x., ren s., sun j., deep residual learning for image recognition, proc. ieee conf. comput. vis. pattern recognit. (cvpr), pp. 770-778, (2016) Trabalho apresentado em conferência sobre *Deep Learning* para reconhecimento de imagens

Lecun y., bottou l., bengio y., haffner p., gradient-based learning applied to document recognition, proc. ieee, 86, 11, pp. 2278-2324, (1998) Artigo sobre aplicações de programas de visão computacional no reconhecimento de documentos

Ruder s., an overview of gradient descent optimization algorithms, (2016) Artigo sobre *Gradient Descending*, otimização de Inteligência Artificial

Simonyan k., zisserman a., very deep convolutional networks for large-scale image recognition, (2014) Artigo sobre *Deep Learning* para reconhecimento de imagens

Yosinski j., clune j., bengio y., lipson h., how transferable are features in deep neural networks? (2014) Trabalho sobre *transfer learning*, otimização de Inteligência Artificial

## Grupo 3

---

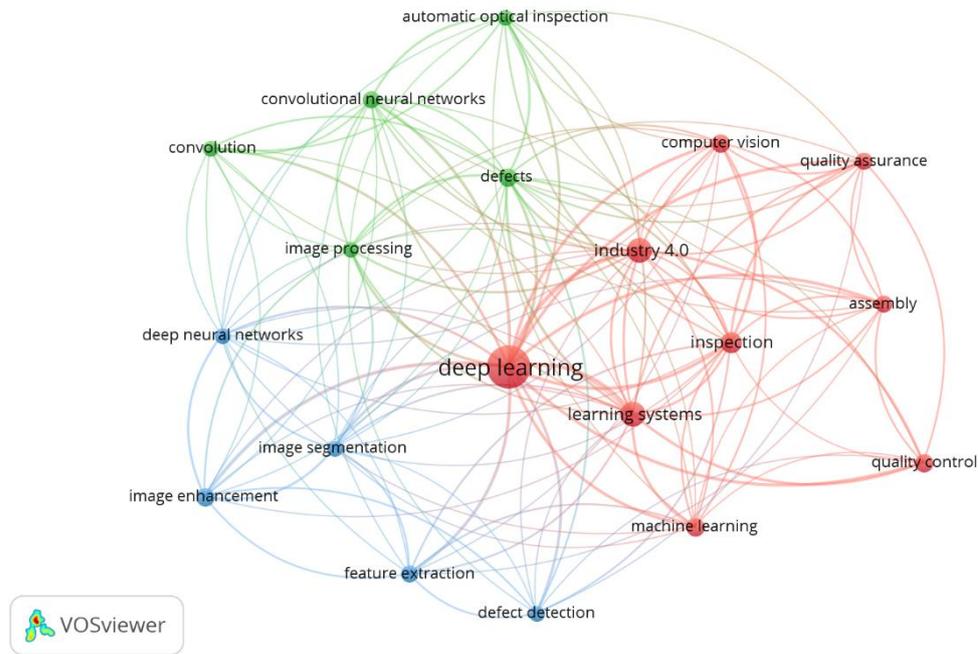
---

<p>Golnabi h., asadpour a., design and application of industrial machine vision systems, robot. comput. - integr. manif., 23, 6, pp. 630-637, (2007)</p>	<p>Artigo sobre aplicações industriais de programas de visão computacional</p>
<p>Jia l., chen c., liang j., hou z., fabric defect inspection based on lattice segmentation and gabor filtering, neurocomputing, 238, pp. 84-102, (2017)</p>	<p>Artigo sobre aplicações industriais de programas de visão computacional</p>
<p>Lecun y., bengio y., hinton g., <i>Deep Learning</i>, nature, 521, 7553, pp. 436-444, (2015)</p>	<p>Artigo sobre principais técnicas e teoria de <i>Deep Learning</i></p>
<p>Malamas e.n., petrakis e.g., zervakis m., petit l., legat j.-d., a survey on industrial vision systems, applications and tools, image vis. comput., 21, 2, pp. 171-188, (2003)</p>	<p>Artigo sobre aplicações industriais de programas de visão computacional</p>

---

Muitas redes de cocitação mostram situações de divergência entre os autores, nas quais são formados grupos bem definidos de autores sem intersecções relevantes entre eles. Entretanto, no caso deste trabalho, a rede de cocitações identificada por meio da análise do corpo de publicações avaliado dentro da literatura científica da área, demonstrou uma intersecção entre os grupos, com vários autores se repetindo em mais de um deles (Tabela 2) isso demonstra a convergência e a relação de proximidade entre as redes de pesquisa traçadas em relação a aplicações com aprendizagem profunda para qualidade de montagem em indústrias.

Uma outra análise importante a ser considerada é a relação entre as palavras-chave dos trabalhos (Figura 11). Palavras-chave são um indicativo interessante de como determinado tema será abordado em um trabalho e como se dá a relação entre dois termos. A relação entre duas palavras em um período pode indicar como a abordagem sobre o tema evoluiu ao longo do tempo.



**Figura 11** - Diagrama de palavras-chave

Algumas relações são intrínsecas à definição dos termos, por exemplo “*Deep Learning*” e “*computer vision*”, isso porque visão computacional é uma técnica dentro de “*Deep Learning*”, da mesma forma que “*convolutional neural network*” é um tipo de “*deep neural network*”. De forma análoga acontece com “*machine learning*” e “*Deep Learning*”, os quais são conjuntos de técnicas diferentes conhecidas como inteligência artificial.

Entretanto, as ligações envolvendo “*quality control*” ajudam a entender como o tema está em contato com termos como “*learning systems*”, “*Deep Learning*” e “*inspection*”, de forma que o controle de qualidade tem alta relação com a inspeção em sistemas produtivos e utiliza de sistemas de aprendizado e aprendizado profundo como técnicas para desenvolver o controle de qualidade. Os trabalhos com essas relações tratam sobre a abordagens de aprendizado profundo na detecção e isolamento de falhas (IQBAL et al., 2019), entendendo o controle de qualidade como detectar e evitar a propagação de falhas em uma linha de produção; sobre a inspeção visual com base em *Deep Learning* (BHANDARI; PARK, 2021; ZAMORA-HERNÁNDEZ et al., 2021); sobre a identificação e classificação de defeitos em peças (KOVILPILLAI; JAYANTHY, 2023) e monitoramento e controle de montagem em tempo real (TORKUL; SELVI; ŞIŞCI, 2022). Com a pluralidade de definições para o termo “controle de qualidade” dentro dessas relações, pode-se entender que técnicas de *Deep Learning* podem ser

aplicadas de formas e em momentos diferentes dos processos de montagem para obter medições distintas de qualidade adaptáveis a diferentes tipos de indústria, nesse caso, computação (IQBAL et al., 2019) e construção civil (KOVILPILLAI; JAYANTHY, 2023).

Outra relação interessante é entre “*automatic optical inspection*”, “*defects*” e “*image processing*”. Essa relação ajuda a compreender como o processamento de imagens pode ser útil na detecção de defeitos durante um processo de montagem. Para integrar uma linha de montagem analógica com um sistema inteligente computadorizado, uma interface que comunique os acontecimentos da linha de montagem de forma que o algoritmo computacional compreenda é necessária (BOCHKOVSKIY; WANG; LIAO, 2020; MUSHTAQ et al., 2023b). Essa interface pode ser construída por meio de sensores (BERGER et al., 2016). A palavra-chave processamento de imagens pode apontar para um tipo de informação que o sensor pode ser capaz de captar. Utilizar imagens como a forma de comunicação entre a linha analógica e o computador ajuda a indicar câmeras como um tipo de sensor a ser utilizado para realizar a comunicação (BERGER et al., 2016; LEI et al., 2018; MUSHTAQ et al., 2023b; ZHANG; WANG, 2022).

A forma como o processamento de imagens foi utilizada na detecção de defeitos varia de acordo com a proposta do trabalho, uma das propostas foi processar imagens em tempo real para classificar imagens com base na existência ou não de falhas (SCHWEBIG; TUTSCH, 2020b), detecção de objetos, na qual os objetos definidos a serem identificados são falhas específicas em determinada peça (KOVILPILLAI; JAYANTHY, 2023; SASSI; TRIPICCHIO; AVIZZANO, 2019), classificação de defeitos específicos com base na comparação entre as imagens recebidas e a imagem de uma peça correta (LE; ZHANG; LIU, 2022).

A relação entre “*Feature Extraction*” e “*Inspection*” pode ajudar a evidenciar como foi automatizado o processo de inspeção das peças montadas. O trabalho “*Computer vision techniques in manufacturing*”(ZHOU; ZHANG; KONZ, 2023) realiza uma revisão sistemática de métodos de visão computacional utilizados em diferentes partes de um processo de manufatura. Esse trabalho explica que “*Feature Extraction*” é a base de muitos outros algoritmos de visão computacional (ZHOU; ZHANG; KONZ, 2023) e pode ser utilizado para encontrar objetos específicos em imagens (AUGUSTAUSKAS; LIPNICKAS; SURGAILIS, 2021; KOVILPILLAI; JAYANTHY, 2023; LE; ZHANG; LIU, 2022; LIU et al., 2019; ZHANG; WANG, 2022; ZHOU; ZHANG; KONZ, 2023), ou para avaliar características sobre bordas de imagens (SHAFI et al., 2023; ZHOU; ZHANG; KONZ, 2023).

### 3.3.1. Aplicação de grafos a sistemas de assistência à montagem

A principal dificuldade em implementar um sistema de assistência à montagem digital é a sincronização entre o estado real da montagem e o estado detectado pelo sistema. Os sistemas de assistência à montagem hoje são desenvolvidos pensando em sistemas estáticos no qual é impossível ocorrer qualquer tipo de mudança (MUELLER; HOERAUF; BASHIR, 2020). Entretanto, isso não se alinha às características de um sistema de montagem dinâmico, no qual o processo pode ser aprimorado pelo próprio operador ou sofrer pequenas mudanças com base na movimentação humana.

Dessa forma, o processo precisa ser previsto com base nas ações e movimentações realizadas pelo operador de montagem e, com isso. A criação de uma estrutura de dados mutável com a definição das atividades do processo e suas relações de interdependência pode apoiar no treinamento de modelos de reconhecimento dessas movimentações para apoiar na detecção das ações e sincronização do processo (MUELLER; HOERAUF; BASHIR, 2020).

O desafio em estabelecer essa estrutura está na complexidade das instruções de montagem o que dificulta a representação dessas por meio de uma estrutura de dados comum (CHEN et al., 2020). A característica dos dados de montagem pensando na grande quantidade de dados históricos gerada, e a heterogeneidade dos dados dificulta a organização dessas informações em estruturas de dados convencionais (LIU et al., 2023). A relação de precedência existente entre as etapas da montagem pode ser organizada da mesma forma que processos de negócios, no formato de correntes, onde uma ação precede a próxima até a finalização do processo (ARCENTALES-CARRION et al., 2022). A organização em correntes é apenas uma das formas de modelar um processo de montagem, este pode ser modelado em termos dos subconjuntos formados por cada atividade de montagem criando uma estrutura de atributos que pode ser descrita em uma árvore de características (CHEN et al., 2020).

Uma forma de organizar um processo de montagem de forma que este represente para um sistema computacional as informações de montagem de um produto é por meio de grafos de conhecimento (LIU et al., 2023). Grafos são estruturas de dados formados de nós, ou vértices, e arestas, que correspondem conexões entre diferentes vértices (SCHAEFFER, 2007). A estrutura de grafos é interessante porque promove a abstração de dados em uma grande variedade de domínios nas quais a estrutura de vértices e arestas compreende relações diferentes e potencialmente complexas entre entidades de um mesmo domínio ou domínios diferentes (HOGAN et al., 2021). Um grafo de conhecimento é uma estrutura representada em grafos que objetiva acumular e reunir conhecimento sobre o mundo real no qual os nós representam

entidades de interesse e as arestas representam as relações entre essas entidades (HOGAN et al., 2021). A aplicação de grafos para a identificação de relações existentes entre objetos do mundo real pode ser interessante porque permite a abstração da complexidade existente no mundo real, e, por isso, pode ser utilizado para representar sistemas de relacionamentos complexos como um processo de montagem.

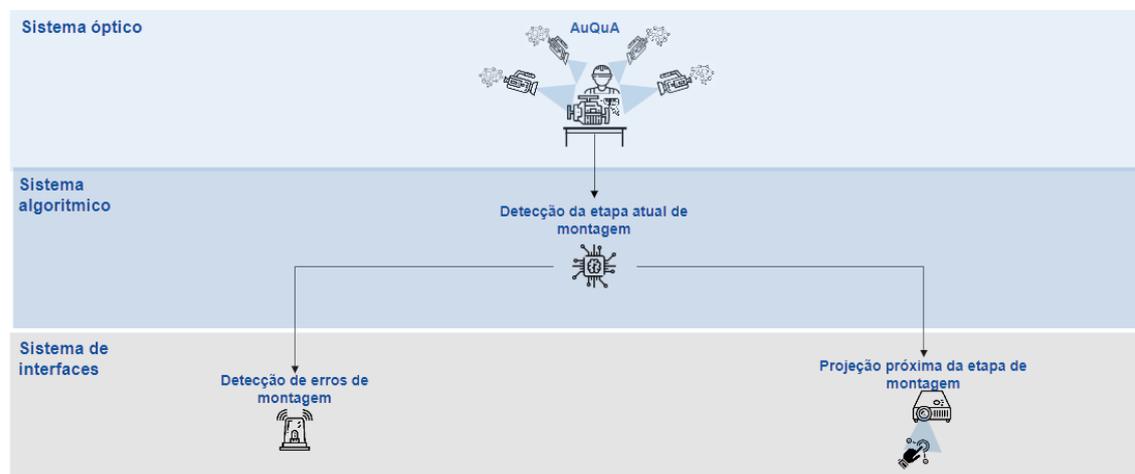
A aplicação de grafos para representar um processo de montagem pode ajudar a lidar com a multiplicidade e heterogeneidade de informações existentes para um mesmo estado do processo ampliando a compreensão deste e possibilitando maior eficiência na interação entre as informações existentes em um processo de montagem (CHEN et al., 2020; LIU et al., 2023). Um grafo de conhecimento utilizado para estruturar informações semânticas de montagem pode ser aplicado para apoiar na decisão de uma etapa subsequente para um AAS, servindo como um guia para o trabalho de montagem em cenários industriais (LIU et al., 2023). Grafos aplicados para a representação de processos de montagem podem ser considerados como grafos de conhecimento por seu viés de representar um sistema complexo com o conhecimento extraído do mundo real de forma a virtualizar as informações relevantes para conduzir um processo de montagem.

Dessa forma, é possível definir uma notação em grafos de conhecimento que refletem um processo de montagem, transformando esse em uma notação compreensível para um programa de computador, o que poderá possibilitar melhores implementações de sistemas de assistência à montagem para processos diversos (LIU et al., 2023).

### 3.4. Caracterização do caso estudado neste trabalho

Um processo de montagem pode ser descrito como a junção de peças em um conjunto finito de tarefas em uma ordem pré-determinada de forma a compor um produto funcional (FERNANDES; FILHO, 2019). Com as mudanças nas demandas do mercado, como ciclos de vida mais curtos dos produtos e uma individualização dos requisitos dos clientes, os benefícios da execução de tarefas altamente repetitivas e pré-definidas tendem a ser mais limitados ao passo em que a importância de sistemas de fabricação altamente flexíveis é potencializada (THAMM et al., 2020).

A aplicação da inteligência artificial na indústria, principalmente em virtude do avanço da indústria 4.0 especialmente em linhas de montagem, é uma crescente sendo observada pela quantidade de publicações acadêmicas sobre o tema, sobretudo a partir do ano de 2022 (BEZERRA et al., 2023; DE QUEIROZ et al., 2023). Nessa tendência, o projeto AuQua tem por objetivo a criação de um sistema de assistência à montagem baseado em inteligência artificial e realidade aumentada que detecte o estado atual da montagem, eventuais erros na execução do processo de montagem e, por meio de realidade aumentada, mostra para o operador, a próxima tarefa do processo (Figura 12) (THAMM et al., 2020).



**Figura 12** - Diagrama da proposta inicial do sistema AuQua

Fonte: Thamm et al. (2021) (adaptado)

O AuQua foi projetado para se adaptar automaticamente às mudanças do processo de montagem sem prejudicar a qualidade do produto montado e tampouco a qualidade da execução do processo (THAMM et al., 2020).

Um sistema de assistência a montagem pode ser construído de formas diversas e ter ou não algum tipo de inteligência artificial em sua composição (CORRÊA et al., 2022; HINRICHSEN; RIEDIGER; UNRAU, 2016; NIKOLENKO et al., 2020). Entretanto, nos trabalhos recentes envolvendo desenvolvimento ou aplicação de sistemas de assistência à montagem, existe a incorporação de alguma forma dessas tecnologias de computação inteligente para a melhoria da qualidade nas linhas de montagem (KIM et al., 2022; LE; ZHANG; LIU, 2022; LEI et al., 2018; ZHANG; WANG, 2022), especialmente com a incorporação de algoritmos de identificação de imagens, como a arquitetura *You Only Look Once* (YOLO) (MUSHTAQ et al., 2023b; YAO et al., 2023; ZHANG; WANG, 2022) ou redes neurais convolucionais (CNN) (KIM et al., 2022; LEI et al., 2018).

Tão importante quanto a escolha de uma arquitetura adequada para o desenvolvimento um sistema de assistência a montagem inteligente é a sincronização entre o estado do sistema percebido pelo AAS e o estado real do sistema físico de montagem (MUELLER; HOERAUF; BASHIR, 2020). Uma das formas de promover a correta sincronização entre o sistema físico e digital de montagem é através da criação de um gêmeo digital para o processo de montagem (WANG et al., 2023). O gêmeo digital é uma forma de transformar uma informação para meio digital por meio da replicação virtualizada do sistema físico (WANG et al., 2023), no caso de processos de montagem, essa replicação pode ser realizada por meio de uma estrutura de grafo (CHEN et al., 2020; HOGAN et al., 2021; SIMONE et al., 2023) que represente os estados e as atividades de um processo e sistema físico de montagem (LIU et al., 2023; SIMONE et al., 2023).

Por isso, o caso avaliado neste estudo, avalia a criação de um grafo que virtualize um processo de montagem, bem como o treinamento de um modelo de inteligência artificial como prova de conceito e teste do protótipo do AuQua para um produto físico real, ainda em estado de protótipo, que consiste em um modelo de caminhão impresso em manufatura aditiva.

# 4 APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA SISTEMAS DE SUPORTE A MONTAGEM

*Nesta secção são apresentadas as definições das estruturas de grafos montadas para a representação do processo de montagem do protótipo do caminhão.*

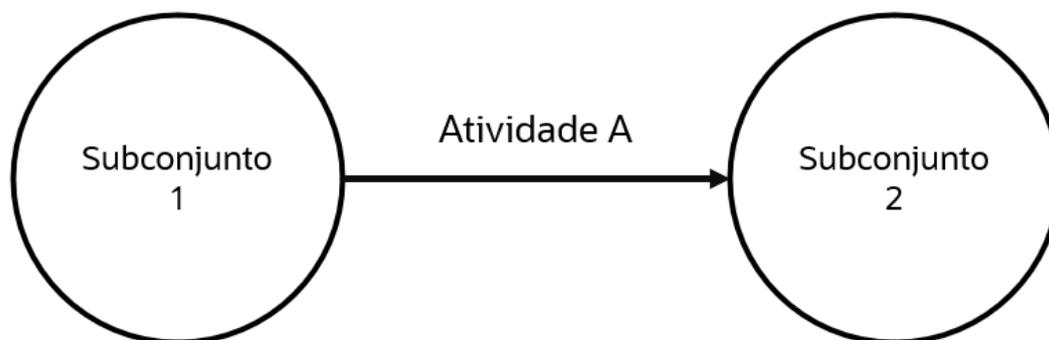
## 4.1. Descrição geral do grafo representativo do processo de montagem

A estruturação de um grafo que represente um processo de montagem pode ser pensada em diferentes perspectivas e cada tipo de organização diferente gera vantagens para a aplicação, bem como traz dificuldades para seu desenvolvimento, entendimento ou aplicação. Um grafo estruturado para ter como nós a informação de subconjuntos da montagem, isso é, a junção intermediária de peças que contribui para a montagem do produto finalizado, seria interessante para demonstrar a relação de dependência entre conjuntos agindo como uma estrutura de requisitos para a montagem de um determinado produto, entretanto, existe uma complexidade maior para representar uma ordem de montagem com esse tipo de abstração.

Outra forma de representar um processo de montagem é por meio da definição de estados de montagem, de forma que um estado contenha atributos que indiquem características daquele processo quando este chega a um estado definido (CHEN et al., 2020), essas características podem ser as peças necessárias para levar o processo de montagem para o estado futuro, qual o subconjunto montado em um determinado estado, quais os subconjuntos que já foram montados em algum momento, qual o sequencial daquele estado, sendo possível alterar os atributos de maneira que possibilite a representação daqueles que melhor se adequam ao processo avaliado. Apesar de conter uma quantidade adicional de atributos, um grafo com nós pensados para representar estados com esses atributos não indica com tanta clareza a relação de dependência entre dois subconjuntos nem a possibilidade de caminhos diferentes de montagem em uma única estrutura, sendo necessário montar um grafo para cada sequência de montagem pensada. Uma vantagem para a aplicação do grafo baseado em estados é a possibilidade de comparações entre grafos distintos, isto é, caminhos de montagem diferentes para um mesmo produto, de forma que permita identificar entre dois grafos definidos, qual o mais otimizado para um determinado parâmetro.

O grafo definido para representar o processo de montagem do protótipo de caminhão precisa contemplar as características principais de um processo de montagem. Dessa forma, entendendo um processo de montagem como uma sequência definida de atividades com relação de precedência entre si que especificam a ordem permitida de tarefas (FERNANDES; FILHO, 2019), é possível definir que o grafo do processo de montagem precisa contemplar as relações de precedência das tarefas executadas.

Uma relação de precedência pode ser representada por meio de estruturas direcionais, aquelas que especificam a ordem de ocorrência de eventos. Dessa forma, em um grafo direcional os vértices são pares ordenados (SCHAEFFER, 2007) de forma que existe uma relação de precedência na ocorrência de um vértice em relação ao seu sucessor.



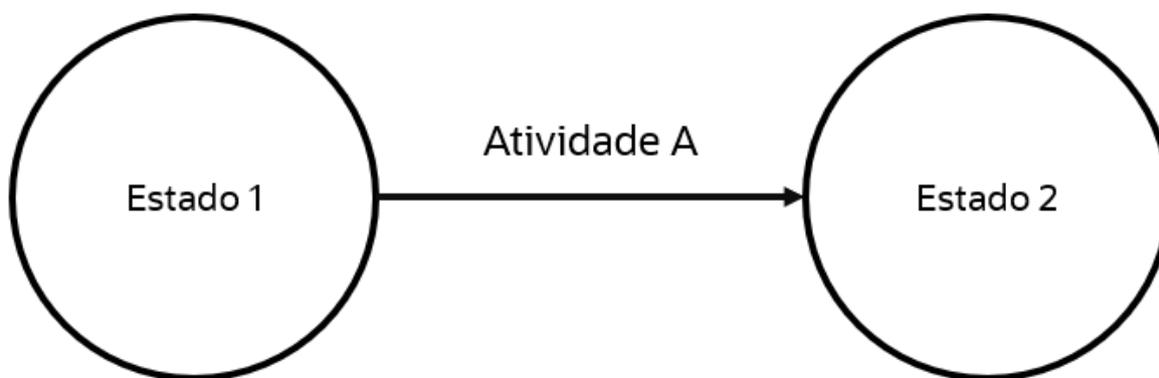
**Figura 13-** Diagrama exemplificando a estrutura de um grafo direcional

A estrutura demonstrada na Figura 13 exemplifica a estrutura de um grafo direcional. Nessa estrutura o “Subconjunto 1” precede a existência do “Subconjunto 2” e a relação entre eles acontece por meio da “Atividade A”. Nessa estrutura, o “Subconjunto 2” não pode existir antes da existência do “Subconjunto 1”, por isso, a construção de um grafo direcional contribui para a construção de um grafo de conhecimento para sistemas de montagem por sua característica sequencial e definida de atividades que guia a execução do processo até a montagem do produto completo, finalizando o processo.

De forma análoga ao processo de montagem do caminhão, o último subconjunto da montagem, que compreende o caminhão completo pode ser entendido como o “Subconjunto 2” da Figura 13 e as peças que compõem o caminhão ainda em seu estado trivial, sem passar por nenhuma atividade de montagem, podem ser entendidas como o “Subconjunto 1”, de forma

que, é impossível, na lógica de montagem tradicional, a existência do caminhão completo sem a existência prévia das peças que o compõem. Dessa mesma maneira, a “Atividade A” da Figura 13 pode ser entendida como o processo completo de montagem do caminhão, visto que este agrupa as peças de maneira organizada para formar o caminhão com o término da execução do processo.

Outra forma possível de montar um grafo representativo de processos de montagem é por meio da definição de estados (CHEN et al., 2020). Estados são definidos como etapas de uma montagem compostos por atributos que entregam mais informação sobre o processo da montagem como um todo do que o subconjunto em trabalho. O diagrama de um grafo pensado em estados de montagem está disposto na Figura 14.



**Figura 14** - Diagrama da estrutura de grafos pensada construída com estados de montagem

De forma análoga ao processo de montagem do caminhão, o estado final da montagem, que compreende o caminhão completo sem etapas posteriores de montagem, pode ser entendido como o “Estado 2” da Figura 14 e o estado inicial de montagem, isso é, aquele no qual não existe nenhum subconjunto montado e todas as peças que compõem o caminhão estão ainda em seu estado trivial, sem passar por nenhuma atividade de montagem, pode ser entendido como o “Estado 1”. Da mesma forma como na Figura 13, a “Atividade A” da Figura 14 pode ser entendida como o processo completo de montagem do caminhão.

## 4.2. Definição dos nós do grafo representativo do processo de montagem do protótipo de caminhão

Os nós da estrutura do grafo construída para o processo de montagem do protótipo de caminhão são definidos pelos estados da montagem que contribuem para o caminhão finalizado. Por definição, o primeiro estado é aquele sem nenhum subconjunto montado, o qual indicará as peças que compõem o primeiro subconjunto da montagem.

Para compor os estados da montagem do protótipo de caminhão, os atributos permitem entender quais as peças já utilizadas na montagem de um subconjunto, quais os subconjuntos já montados em um determinado estado e quais as peças para compor o subconjunto do próximo estado de montagem, conforme disposto na Tabela 3.

**Tabela 3** - Atributos de estados de montagem

Atributo	Descrição
Id	Identificação única do estado
Nome	Descrição do subconjunto montado no final do estado
Subconjuntos Iniciais	Subconjuntos iniciais do estado (necessários para a montagem no estado)
Subconjuntos Passados	Todos os subconjuntos já montados pelo sistema até o início do estado
Subconjunto Final do Estado	Código identificador do subconjunto montado pelo estado

Dessa forma, o nó representante do estado de montagem atual trás maiores informações sobre o sistema em um determinado momento da montagem, permitindo análises e comparações melhores entre estados diferentes e pode contribuir para trazer mais conhecimento para o operador de montagem que executará o processo.

De forma a entender cada atributo do Estado de montagem, o menor subconjunto possível é uma peça individual integrante do caminhão. Isso porque, um subconjunto é um agregado de peças que compõe um produto completamente montado (CHEN et al., 2020), um agregado de

uma única peça, é, portanto, um subconjunto, para discriminá-lo dos subconjuntos montados, chamamos os subconjuntos de uma peça de subconjuntos triviais.

Os subconjuntos triviais do caminhão e as quantidades necessárias para a montagem completa do protótipo estão dispostas na Tabela 4.

**Tabela 4** – Subconjuntos triviais do protótipo do caminhão

Id	Nome	Quantidade
1	Roda	8
2	Eixo	4
3	Cabine	1
4	Plataforma da cabine	1
5	Caçamba	1
6	Plataforma da caçamba	1
7	Porta lateral	2
8	Porta da caçamba	1
9	Teto da cabine	1
10	Teto da caçamba	1
11	Parafuso	1

A partir dessas peças, são formados todos os demais subconjuntos para garantir a montagem completa do protótipo. Essas peças irão compor o atributo “Peças Futuras” porque, a partir da descrição de quais peças formam o subconjunto do próximo estado de montagem, o operador sabe, com mais clareza, quais peças permitirão o avanço do sistema para o próximo estado, diminuindo a possibilidade de erros também na escolha das peças.

Os subconjuntos podem ser formados por outros subconjuntos não triviais, isso é, aqueles que já passaram por atividades de montagem, entretanto, todos são formados por subconjuntos triviais, uma vez que todos são compostos por peças que formam o caminhão ao final do processo de montagem. Estes também estarão no sistema como o atributo “Peças Futuras” para a composição do subconjunto do estado futuro da montagem.

Para estabelecer um relacionamento entre os subconjuntos, de forma a compor o atributo “Peças Futuras” a **Tabela 5** foi desenhada com as informações de composição de cada um dos subconjuntos em relação aos seus subconjuntos imediatamente anteriores e às peças que o compõem, coluna essa disposta como Composição Trivial em referência à nomenclatura “Subconjunto Trivial” para indicar as peças da montagem de determinado subconjunto.

É importante referenciar que, de forma lógica, existem outras possibilidades para a montagem do caminhão, por exemplo criar um subconjunto composto pelas peças 3, 7 e 9 (**Tabela 4**) e, somente após a montagem desse subconjunto, acrescentar a peça 4, diferente do processo traçado para a composição do subconjunto 13 (**Tabela 5**) composto pelas peças 3 e 4. A troca na ordem da montagem das peças origina subconjuntos diferentes para cada etapa do processo o que altera a estrutura dos grafos desenvolvidos para representar o processo.

Para este primeiro modelo, a ordem estabelecida de montagem será aquela mapeada para o processo de montagem do caminhão disposto no trabalho de iniciação científica “Explorando o uso do BPMN para mapear a implementação de Inteligência artificial e realidade aumentada em linhas de montagem: Um estudo do processo de montagem do Truck” (LÚCIA et al., 2023).

Como uma característica do processo de montagem do protótipo do caminhão, o produto completamente montado contém todas as peças que o compõem, portanto, a composição trivial deste corresponde a todas as peças.

**Tabela 5** - Composição de subconjuntos

Id	Nome	Quantidade	Composição Trivial	Composição
13	Cabine - Plataforma	1	3, 4	3, 4
14	Caçamba - Plataforma	1	5, 6	5, 6
15	Eixo - Semi Montado	4	1, 2	1, 2
16	Cabine - Plataforma - Eixo	1	1, 2, 3, 4	13, 15, 1
17	Caçamba - Plataforma - Eixo	1	1, 2, 5, 6	14, 15, 1
18	Cabine - Teto	1	1, 2, 3, 4, 9	16, 9
19	Cabine - Portas	1	1, 2, 3, 4, 9, 7	18, 7
20	Caçamba - Teto	1	1, 2, 5, 6, 10	17, 10
21	Caçamba - Porta	1	1, 2, 5, 6, 10, 8	20, 8
22	Cabine - Caçamba	1	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	19, 21
23	Caminhão	1	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11	22

Além da análise da composição dos subconjuntos de forma binária, isto é, indicando a existência ou não de uma peça, por existir a repetição de peças na montagem do protótipo do caminhão, é importante, também, traçar a relação das quantidades de cada peça existentes em um subconjunto. Nessa avaliação, pela característica do processo de montagem utilizado como modelo, a quantidade de peças existente no início é a mesma quantidade de peças utilizada no protótipo montado, isso é, o subconjunto final da montagem, como demonstrado na Tabela 6.

**Tabela 6** - Quantidades de cada peça na composição de cada subconjunto

<b>Id</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>	<b>9</b>	<b>10</b>	<b>11</b>
<b>13</b>			1	1							
<b>14</b>					1	1					
<b>15</b>	4	4									
<b>16</b>	4	2	1	1							
<b>17</b>	4	2			1	1					
<b>18</b>	4	2	1	1					1		
<b>19</b>	4	2	1	1			2		1		
<b>20</b>	4	2			1	1				1	
<b>21</b>	4	2			1	1		1		1	
<b>22</b>	8	4	1	1	1	1	2	1	1	1	
<b>23</b>	8	4	1	1	1	1	2	1	1	1	1

A avaliação da quantidade de cada peça nos conjuntos subsequentes é importante para definir quantas vezes uma mesma peça participa do processo de montagem para, com essa informação, criar regras no sistema para evitar ocorrências infinitas das atividades que envolvem essas peças.

### **4.3. Definição das arestas do grafo representativo do processo de montagem do protótipo de caminhão**

As arestas da estrutura do grafo construída para o processo de montagem do protótipo de caminhão são definidas pelas atividades responsáveis em agregar subconjuntos para a composição do caminhão finalizado. As atividades são definidas com uma ordem de ocorrência. Uma atividade que liga o primeiro estado ao segundo estado irá acontecer antes de uma atividade que muda o sistema do estado 3 para o estado 4.

A definição de quais atividades são necessárias para realizar as mudanças de estado foi realizada por meio do mapeamento do processo de montagem do caminhão, na qual, por meio da notação BPMN, foi descrita em um diagrama quais as atividades necessárias que compõem

a montagem do protótipo do caminhão (LÚCIA et al., 2023). Com base no mapeamento das atividades, foi possível entender quais os subconjuntos participantes de sua execução quais os subconjuntos necessários para sua realização e, a partir disso, entender quais os subconjuntos formados após a execução de determinada atividade, possibilitando, com isso, detalhar os relacionamentos entre os subconjuntos e, assim, definir as relações entre os nós do grafo por meio das arestas.

A Tabela 5 indica a existência de relações entre os subconjuntos, entretanto, entendendo as atividades que realizam essa relação é possível detalhar melhor as arestas da estrutura de grafo e, com isso, indicar ao operador de montagem, qual a atividade a ser executada por meio do AAS.

#### 4.4. Construção do processo de montagem em uma estrutura de grafo

A partir das definições específicas para o processo de montagem do protótipo do caminhão, foi possível detalhar a construção de uma estrutura de grafo para a construção de um modelo virtual que o representasse. A construção da estrutura de grafo foi realizada por meio da linguagem de programação *open source* Python® (PYTHON SOFTWARE FOUNDATION, 2001) com a utilização de recursos da biblioteca NetworkX® (SWART et al., 2008).

O Algoritmo 2, construído para a definição do grafo funciona por meio da leitura do mapeamento de processo da montagem do caminhão (LÚCIA et al., 2023), extração das atividades de interesse, identificação dos subconjuntos participantes do estado e atividade e, por fim, a identificação da relação entre dois estados de montagem por meio das atividades mapeadas.

---

**Algoritmo 2** : Geração do grafo representativo do processo de montagem manual do caminhão

---

- 1: Inicializar *lista\_atividades* = carrega atividades do tipo montagem do processo de montagem
- 2: Inicializar *lista\_subconjuntos* = carrega informações dos subconjuntos do processo de montagem
- 3: Inicializar *grafoEstados* = estrutura de grafo vazia
- 4: Inicializar *sequencia\_montada* = []
- 5: Inicializar *estado* com as informações id, subconjuntosIniciais, subconjuntosPassados e SubconjuntoFinalEstado
- 6: Inicializar *atividade* com as informações id, mão, nome e notas
- 7: Inicializar *i* =  
0, *n* = 0
- 8: **enquanto** *i* < tamanho(*lista\_atividades*) **faça**:
- 9:     *estado.id* = *i*
- 10:     *estado.subconjuntosIniciais* = Subconjuntos participantes da *i*-ésima atividade de montagem

```

11:  estado.subconjuntosPassados = sequencia_montada
12:  estado.subconjuntoFinalEstado = Subconjunto gerado pela i-ésima atividade de montagem
13:  sequencia_montada.adicionar(estado.subconjuntoFinalEstado)
14:  Inicializar nome = Descrição do i-ésimo estado de montagem
15:  grafoEstados.adicionarNó(nome, estado)
16:  i = i + 1
17:  final enquanto
18:  enquanto n < tamanho(lista_atividades) faça:
19:    atividade.id = n
20:    atividade.mao = Mão do operador que realizará a n-ésima atividade
21:    atividade.nome = Descrição da n-ésima atividade
22:    atividade.notas = Detalhamento da n-ésima atividade
23:    se n < (tamanho(lista_atividades) - 1)
24:      Inicializar identificador_origem = lista_montagem['Subconjunto de Saída'][n]
25:      Inicializar identificador_destino = lista_montagem['Subconjunto de Saída'][n+1]
26:      grafoEstados.AdicionarAresta(lista_subconjuntos[Identificador_origem]['Nome'],
27:      lista_subconjuntos[Identificador_destino]['Nome'] )
27:    final se
28:    n = n + 1
29:  final enquanto

```

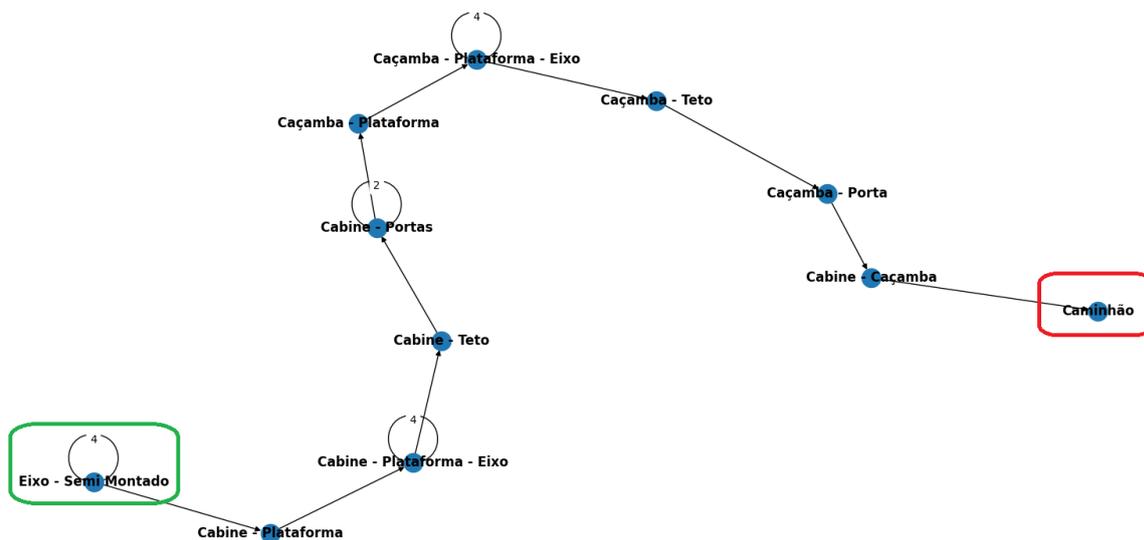
---

Algoritmo 2 - Geração do grafo representativo do processo de montagem manual do caminhão

#### 4.5. Detalhamento da estrutura

O grafo foi construído pensando em detalhar qual a sequência de estados de montagem traçada desde o início ao final da montagem do protótipo do caminhão. Além da informação de sequência, também se demonstra no grafo, a quantidade de ações repetidas, por meio dos números expostos nos loops. Dessa forma, para cada seta ligando dois nós, a atividade de montagem que é executada entre um estado e outro é realizada apenas uma vez. Entretanto, quando a mesma atividade deve se repetir, cria-se uma estrutura de repetição em um estado.

Essa estrutura é representada no diagrama do grafo (Figura 15) como uma alça que liga um nó a ele mesmo. Nessa alça consta a informação da quantidade de repetições de uma mesma atividade a ser realizada antes que um estado possa passar para o estado sucessor.



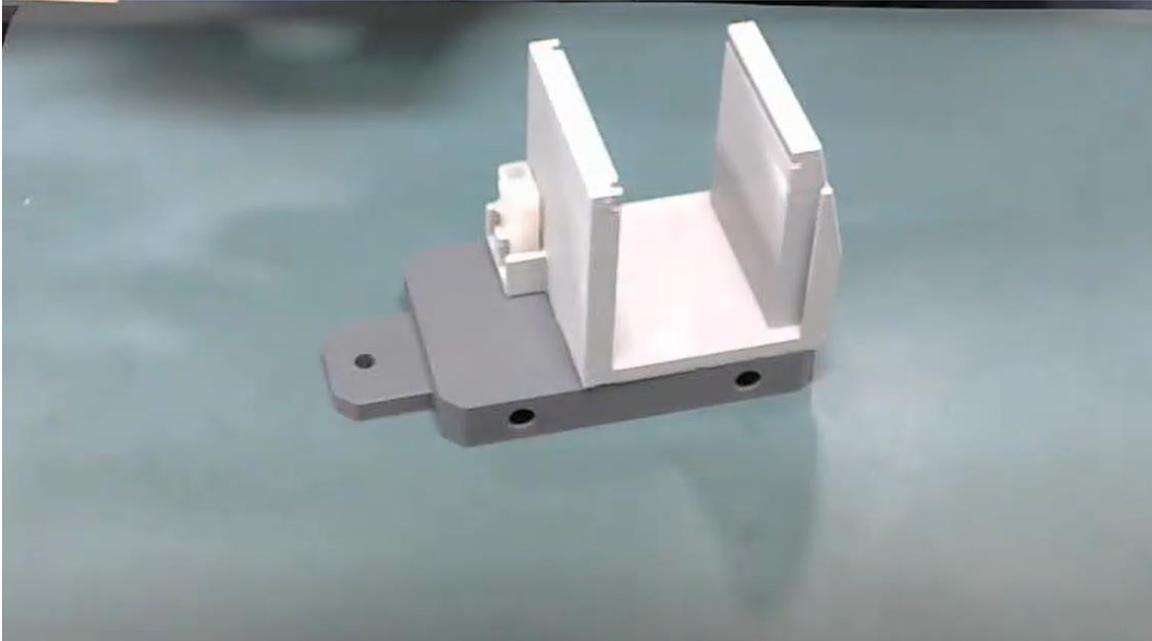
**Figura 15** - Diagrama do grafo representativo do processo de montagem do caminhão

Assim, para os estados “Eixo-Semi-Montado” (Figura 16), “Cabine-Plataforma-Eixo” e “Caçamba-Plataforma-Eixo” serem finalizados, são necessárias quatro repetições de uma atividade de montagem. Já para o estado “Cabine-Portas” essa repetição acontece duas vezes.



**Figura 16** - Final do Estado Eixo-Semi-Montado

Para as setas que ligam um estado a outro, a atividade só deve ser realizada uma vez, de forma que a execução correta da atividade representada por uma aresta que liga um nó a outro no grafo, garante a passagem do sistema de um estado para o seu sucessor.



**Figura 17** - Subconjunto final do estado Cabine Plataforma

O grafo se inicia com o estado “Eixo-Semi-Montado” e segue uma estrutura sequencial de montagem até chegar no estado final de montagem, o “Caminhão”. Não necessariamente o subconjunto formado por um estado participa da montagem do seu estado sucessor, a exemplo disso, existe o estado “Eixo-Semi-Montado” ligado ao estado “Cabine-Plataforma” (Figura 17), entretanto, o subconjunto 15 “Eixo-Semi-Montado” (**Tabela 5**) não participa da montagem do subconjunto 13 “Cabine-Plataforma” (**Tabela 5**), ou seja, a relação entre dois estados não significa a relação entre dois subconjuntos, apenas indica a ordem da precedência de dois estados. A mesma situação se repete na relação entre os estados “Cabine-Portas” e “Caçamba-Plataforma”.

#### **4.6. Detalhamento Nós e Arestas**

Além da informação do subconjunto final e da sequência de subconjuntos montados, o grafo contém, em cada nó, a informação de quais subconjuntos participam de um estado, quais foram todos os conjuntos já montados até o sistema atingir um estado e qual o conjunto final montado em um estado Tabela 7.

**Tabela 7 - Atributos nós**

Subconjuntos				
id	nome	Iniciais	Passados	FinalEstado
3	Eixo - Semi Montado	1, 2	□	15
4	Cabine - Plataforma	3, 4	['15']	13
8	Cabine - Plataforma - Eixo	1, 16	['13', '15']	16
9	Cabine - Teto	9, 16	['13', '15', '16']	18
11	Cabine - Portas	7, 19	['13', '15', '16', '18']	19
12	Caçamba - Plataforma	5, 6	['13', '15', '16', '18', '19']	14
16	Caçamba - Plataforma - Eixo	1, 17	['13', '14', '15', '16', '18', '19']	17
17	Caçamba - Teto	17, 10	['13', '14', '15', '16', '17', '18', '19']	20
18	Caçamba - Porta	20, 8	['13', '14', '15', '16', '17', '18', '19', '20']	21
19	Cabine - Caçamba	20, 21	['13', '14', '15', '16', '17', '18', '19', '20', '21']	22
20	Caminhão	22, 11	['13', '14', '15', '16', '17', '18', '19', '20', '21', '22']	23

As informações presentes nos nós são importantes para ajudar na definição do estado da montagem e no andamento da montagem realizada pelo sistema. De forma que, sabendo qual o estado da montagem no qual o sistema se encontra, é possível saber qual o desenvolvimento da

montagem em um determinado ponto e o que ainda deve acontecer para a finalização do processo.

Nas arestas, o grafo contém a atividade que liga um estado ao seu sucessor, a descrição dessa atividade, qual mão realiza e informações extras daquela atividade Tabela 8.

**Tabela 8** - Atributos arestas

id	Descrição	Mão	Detalhamento
104	Encaixar Eixo na Roda	D	O encaixe é realizado de cima para baixo em todas as 4 rodas
105	Encaixar Suporte da Cabine na Cabine	E	O encaixe é realizado da esquerda para direita, seguindo o vinco da peça
114	Encaixar Roda-Eixo no Suporte da Cabine	E	O encaixe é realizado de baixo para cima, seguindo o orifício
117	Encaixar Roda no eixo da Roda-Eixo	D	O encaixe é realizado de cima para baixo, no eixo excedente
123	Encaixar Teto da Cabine no conjunto	D	O encaixe é realizado na horizontal, seguindo o vinco da peça
121	Encaixar Vidro Lateral no conjunto	D	O encaixe é realizado de cima para baixo, seguindo o vinco da peça
125	Encaixar Vidro Lateral no conjunto	D	O encaixe é realizado de cima para baixo, seguindo o vinco da peça
133	Encaixar Suporte do Trailer no Trailer	E	O encaixe é realizado da esquerda para direita, seguindo o vinco da peça
142	Encaixar Roda-Eixo 4 no Suporte do Trailer	E	O encaixe é realizado de baixo para cima, seguindo o orifício
145	Encaixar Roda 4 no eixo da Roda-Eixo	D	O encaixe é realizado de cima para baixo, no eixo excedente
149	Encaixar Teto do Trailer no conjunto	D	O encaixe é realizado na horizontal, seguindo o vinco da peça
151	Encaixar Lateral do Trailer no conjunto	D	O encaixe é realizado de cima para baixo, seguindo o vinco da peça
158	Encaixar Cabine no Trailer	E	O encaixe é realizado na horizontal, seguindo a predisposição das peças

A descrição da aresta descreve a tarefa com base no mapeamento do processo da montagem manual do protótipo do caminhão (LÚCIA et al., 2023), e a descrição da atividade é o mínimo de informação necessário para garantir o entendimento e execução plena de uma tarefa.

A “mão” que realiza a tarefa é o autor do processo. No caso de uma montagem manual do protótipo do caminhão, cada mão é responsável por uma parte da execução de cada atividade (LÚCIA et al., 2023), da mesma forma que acontecem com autores de um processo, definidos

em um mapeamento de processos. As letras D e E significam, respectivamente, Direita e Esquerda e indicam a mão dominante envolvida na execução de uma tarefa **Tabela 8**.

O detalhamento são informações extras expostas no mapeamento do processo de montagem manual do protótipo do caminhão. Elas foram acrescentadas como forma de entregar maiores detalhes sobre a execução de uma tarefa (LÚCIA et al., 2023).

## **4.7. Construção de conjunto de dados para treinamento de algoritmo inteligente**

### **4.7.1. Data Augmentation**

Para aplicar o grafo como uma forma de permitir a sincronização entre o sistema real e o sistema digital de montagem, é necessário aplicar uma forma eficiente de realizar a sincronização do sistema em cada estado. Pensando na escalabilidade do projeto, ainda que definidos subconjuntos como atributos de entrada do estado, utilizei as peças do caminhão como forma de identificar a entrada do estado, dada a inviabilidade do mapeio de todos os subconjuntos da montagem de produtos mais complexos.

Por isso, o conjunto de dados construído para o treinamento do algoritmo inteligente responsável pela interface entre o sistema físico e o digital, foi construído por meio de técnicas de *data augmentation* aplicadas às informações das peças do protótipo do caminhão.

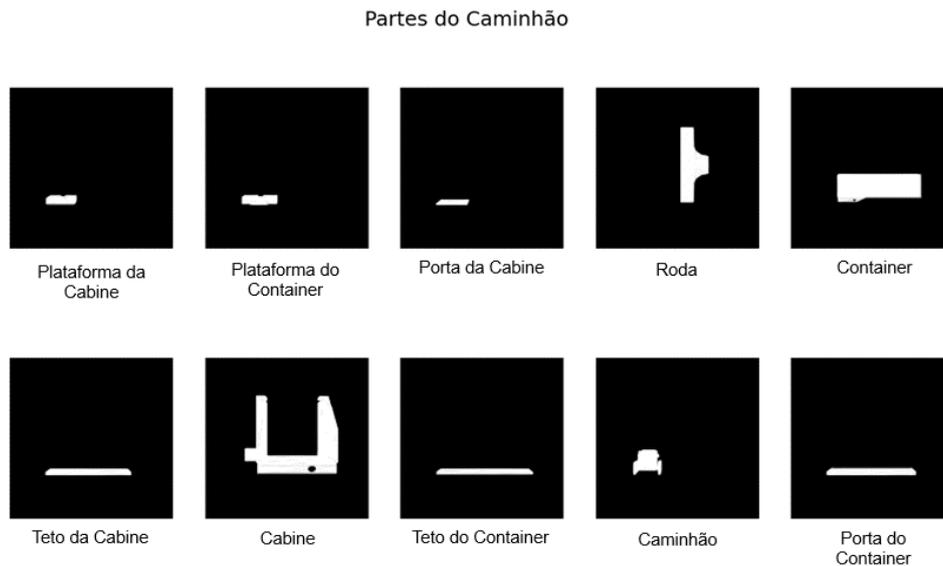
*Data augmentation* é o processo que utiliza técnicas computacionais para gerar artificialmente um conjunto de dados adicionais para aumentar a quantidade de dados de treinamento de um modelo, gerando variantes realistas dos dados disponíveis na amostra (GÉRON, 2022). Esse processo é utilizado para evitar o *overfitting* de modelos de inteligência artificial (SHORTEN; KHOSHGOFTAAR, 2019). *Overfitting*, ou super ajustamento, é o fenômeno no qual um modelo se ajusta demais aos dados de treinamento e não performa tão bem em dados de teste e validação, isto é, não generaliza o aprendizado acerca do problema para o qual está sendo treinado (GÉRON, 2022) e, como consequência, não se torna um modelo adequado para utilização em casos reais.

O processo de *data augmentation* pode ser realizado por meio de diferentes transformações nos dados e tende a melhorar a performance geral do modelo contanto que os dados gerados por este sejam variações dos dados originais (GÉRON, 2022).

Além do *overfitting* estas técnicas podem ter aplicações na transformação do dataset em algo mais próximo dos dados utilizados no mundo real para endereçar o problema para o qual o modelo está sendo treinado (SHORTEN; KHOSHGOFTAAR, 2019). No caso de sistemas de assistência à montagem aplicados em linhas de montagem industrial, o principal tipo de sensor são câmeras que captam imagens bidimensionais dos objetos participantes da montagem (IEAMSAARD; SANDNES; MUNEEAWANG, 2017; LE; ZHANG; LIU, 2022; SCHWEBIG; TUTSCH, 2020b; ZHANG; WANG, 2022; ZHOU; ZHANG; KONZ, 2023). Por isso, o processo de *data augmentation* foi realizado para transformar os dados dos modelos CAD das partes do caminhão em imagens bidimensionais de forma a melhor adequar o *dataset* de treino aos dados coletados no mundo real para o problema endereçado pelo modelo.

#### 4.7.2. Conversão do formato de arquivo

Os dados originais do protótipo do caminhão foram construídos em CAD e salvos em formato stl. Esse formato de arquivo, abreviação da palavra “*stereolithography*” é a modelagem tridimensional das peças do caminhão. Em um sistema real, aplicado em linhas de montagem, o sensoriamento mais comum é realizado por meio de câmeras, as quais captam imagens bidimensionais dos objetos integrantes do processo (IEAMSAARD; SANDNES; MUNEEAWANG, 2017; LE; ZHANG; LIU, 2022; SCHWEBIG; TUTSCH, 2020b; ZHANG; WANG, 2022; ZHOU; ZHANG; KONZ, 2023). Portanto, a principal parte do



**Figura 18** - Coleção de imagens das partes do caminhão em vista lateral esquerda

processo de *data augmentation* foi realizar a construção de um conjunto de dados de treinamento em arquivos bidimensionais.

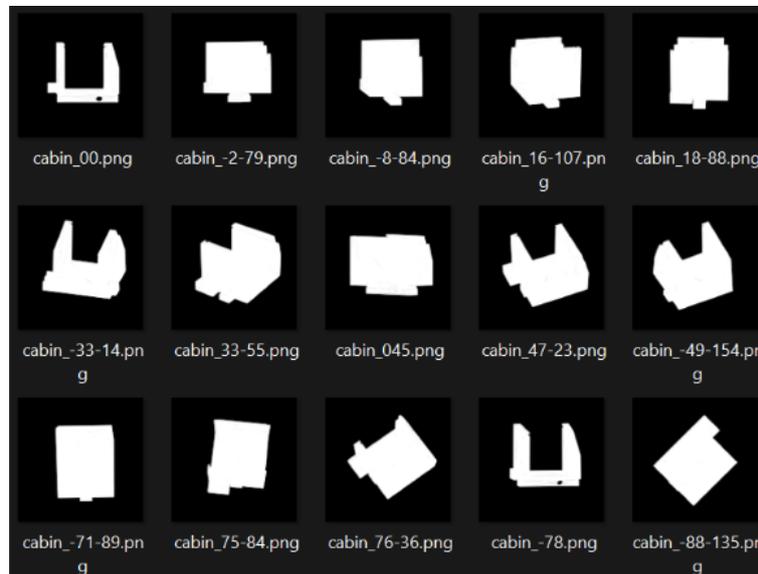
Essa transformação foi realizada com ajuda da biblioteca de visualização de dados para programação em Python® chamada Matplotlib® e da biblioteca, também para Python®, que permite a leitura de arquivos stl chamada STL®. O algoritmo para realizar essa transformação foi integrado às demais etapas do processo de *data augmentation* e, por isso, será descrito ao final do capítulo.

#### 4.7.3. Rotação

Uma segunda etapa do processo de *data augmentation* foi realizar a geração das imagens das peças em rotações diversas e aleatórias. O processo de rotação das imagens foi realizado com base na geração de ângulos aleatórios para os três eixos de rotação de um objeto

tridimensional (x, y e z) por meio da biblioteca Random® para linguagem de programação Python®. Essa técnica está dentro dos métodos tradicionais de *data augmentation* e consiste em um tipo de transformação afim geométrica (MUMUNI; MUMUNI, 2022).

Após a geração dos ângulos, estes foram aplicados a todas as partes do caminhão e foi capturada uma imagem da peça rotacionada no ângulo determinado.



**Figura 19** - Imagens com vistas em ângulos aleatórios da peça 'cabine'

Além de ser um método tradicional de *data augmentation*, o processo de rotação das peças foi realizado porque, para realizar uma montagem, um operador necessita manusear a peça e, com isso, realizar rotações em ângulos diversos. Dessa forma, uma mesma peça pode ser “vista” pelas câmeras que “enxergam” uma linha de montagem em angulações diferentes e, por vezes, não alinhadas com as vistas padronizadas para a visualização de uma peça (frontal, lateral esquerda, lateral direita, superior e inferior).

Para todas as peças, são geradas imagens nas vistas padronizadas frontal, lateral esquerda, lateral direita, superior e inferior, em 200 ângulos aleatórios gerados pela biblioteca Python ® Random e em 3 rotações de 45° para vista lateral direita, lateral esquerda e superior, totalizando 209 rotações diferentes por peça.

#### 4.7.4. Alterações no zoom das imagens

Da mesma forma como o processo de montagem demanda a rotação das peças, o operador pode posicionar uma mesma peça em várias distâncias diferentes em relação à câmera. Isso gera uma diferença na informação que o *zoom* da imagem da peça poderá ter.



**Figura 20** - Zooms diferentes para a cabine do caminhão

Por isso, foi realizado o processo de gerar imagens com aproximações diferentes da peça geradas de forma aleatória para cada rotação de cada peça.

O processo de *scaling*, isto é a geração de aproximações ou afastamentos na imagem (*zoom*) também é um método tradicional de *data augmentation* incluso nos métodos de transformação afim (MUMUNI; MUMUNI, 2022).

Como é possível perceber pela **Figura 20**, alterar o *zoom* das imagens traz o problema de aproximação ou distanciamento exagerado. Mesmo que os limites de aproximação e distanciamento sejam definidos na geração dos dados, a rotação das peças pode ocasionar a geração de imagens totalmente brancas ou pretas, isto é, ou com o *zoom* completo em uma parte da peça ou como *zoom* completo em uma parte do espaço ao redor da peça.

Para cada imagem foram gerados 5 *zooms* diferentes, totalizando 1254 imagens para cada peça (209 rotações + 1045 *zooms*).

#### 4.7.5. Remoção de imagens

A existência de imagens totalmente pretas ou brancas não entrega informações relevantes para o treinamento do modelo. Isso porque o foco em uma parte do meio de uma peça de forma que se torne irreconhecível qualquer alteração nas imagens não permite ao modelo um reconhecimento das imagens de forma relevante.

Por isso, para a geração de imagens que agreguem informação ao modelo treinado, todas as imagens completamente brancas ou completamente pretas foram removidas do conjunto de imagens gerado.



**Figura 21** - Exemplo de imagem com foco no espaço ao redor da peça (completamente preta)

Essa etapa gera um desbalanceamento no conjunto de dados, isto é, a quantidade desigual de imagens para cada uma das peças, fazendo com que algumas peças tenham 1254 imagens válidas enquanto outras tenham em torno de 800 imagens válidas. Essa questão foi solucionada no final do processo de criação do conjunto de dados com o balanceamento do conjunto total.

#### **4.7.6. Mudança no plano de fundo das imagens**

Em uma linha de montagem, o que está atrás da peça a ser reconhecida, isto é, o plano de fundo de uma peça, não tem uma coloração sólida tal qual as imagens apresentadas até o momento. Por isso, além de todas as transformações realizadas até o capítulo “Remoção de

imagens” foi realizada, também, a geração de ruído por meio da alteração do plano de fundo das imagens para ilustrações arbitrárias de forma a gerar uma “confusão” com a peça representada na imagem.

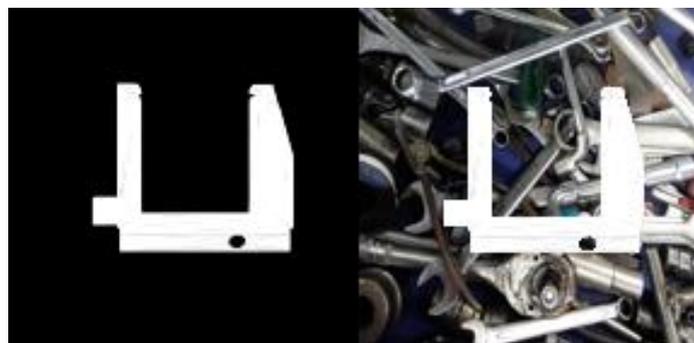
Essa técnica é útil para treinar modelos no reconhecimento de objetos que, no mundo real, estarão em ambientes bagunçados, desorganizados (PATRIZI; GAMBOSI; ZANZOTTO, 2021), como o exemplo de uma linha de montagem manual.

Cada peça poderá ter um plano de fundo aleatório entre quatro opções, dispostas na Figura 22.



**Figura 22** - Possibilidades de plano de fundo

A escolha dessas imagens para compor o plano de fundo foi pensada para gerar confusão com as peças, criando, assim, o ruído. A primeira imagem foi escolhida por representar ferramentas de forma não ordenada. A segunda, foi pensada por além de demonstrar ferramentas, estas são de cores diferentes. A terceira e a quarta imagens foram pensadas por serem compostas de uma grande quantidade de cores dispostas de forma aleatória. A inserção do ruído na alteração do plano de fundo não foi feita pensando para substituir o conjunto de dados existente, mas sim, para complementá-lo, dessa forma, existe uma mesma imagem com o fundo liso preto e com um dos planos de fundo possíveis dentro das quatro possibilidades.



**Figura 23** - Peça da cabine com e sem plano de fundo

A criação da imagem com o plano de fundo aleatório foi pensada para que o modelo não aprenda a desprezar o fundo, mas sim, a reconhecer a peça.

Todas as possibilidades de plano de fundo foram extraídas de pesquisas no site de buscas Google e nenhuma delas apresentava restrição de uso por direitos autorais.

#### 4.7.7. Algoritmo

A realização de todos esses processos de transformação do conjunto de dados foi feita por meio de um algoritmo de programação que realizou essas transformações e possibilitou a geração de 20000 imagens para o treinamento do modelo.

Essas imagens e o **Algoritmo 3** estão disponíveis na página do GitHub: <https://github.com/isabelcgomes/truckImages> (GIANNECCHINI, 2024), na qual se encontram os códigos utilizados para a geração das imagens bem como as imagens geradas.

---

#### **Algoritmo 3** : Geração do conjunto de dados de imagens do caminhão

---

```
1: Inicializar categorias = carrega lista de peças
2: Inicializar planos_de_fundo = carrega lista de planos de fundo possíveis
3: Inicializar pastas temporárias = cria estrutura de pastas para armazenar imagens
4: Inicializar pastas definitivas = cria estrutura de pastas para armazenar imagens
5: Inicializar lista_de_ângulos com 9 angulações referentes às vistas padrão
6: para cada categoria em categorias:
7:   se quantidade_de_itens em pastas_definitivas < 2024
8:     Inicializar diferença = (2024 - quantidade_de_itens)/3
9:     Inicializar x = 0, i = 0
10:    enquanto x < diferença faça:
11:      lista_de_ângulos.Adicionar(gerarÂnguloAleatório, gerarÂnguloAleatório,
12:        gerarÂnguloAleatório)
13:      x = x + 1
14:    final enquanto
15:    para cada conjunto_de_três_ângulos em ângulos:
16:      GerarImagem(ângulo x = conjunto_de_três_ângulos[0], ângulo y =
17:        conjunto_de_três_ângulos[1], ângulo z = conjunto_de_três_ângulos[2])
18:      SalvarImagemEmPastaTemporária
19:    final para cada
20:    para cada imagem em pasta_temporária:
21:      enquanto i < 2 faça:
22:        GerarZoom
23:        SalvarImagemEmPastaTemporária
24:        l = l + 1
25:      final enquanto
```

- 24: **final para cada**  
 25: **para cada imagem em pasta\_temporária:**  
 26:     AcrescentarPlanoDeFundo  
 27:     SalvarImagemEmPastaTemporária  
 28: **final para cada**  
 29: **para cada imagem em pasta\_temporária:**  
 30:     MoverImagemParaPastaDefinitiva  
 31: **final para cada**  
 32: ApagarPastasTemporáriasVazias

---

**Algoritmo 3** - Geração do conjunto de dados de imagens do caminhão

O Algoritmo 3 foi escrito na linguagem de programação Python® e foi utilizado como uma forma de automatizar o procedimento de geração das imagens. No total, foram geradas 21582 imagens divididas em 10 categorias, sendo 9 peças e o caminhão completo (Tabela 9).

**Tabela 9** - Quantidade de imagens por classe

<b>Classe</b>	<b>Peça Correspondente</b>	<b>Quantidade de imagens</b>
cabin	Cabine	2332
cabin_door	Porta Lateral	2028
cabin_ground_plate	Plataforma da Cabine	2232
Cabin_roof	Teto da Cabine	2036
Container	Container	2032
container_door	Porta do Container	2024
container_roof	Teto do Container	2198
tire	Rodas	2328
trailer_ground_plate	Plataforma do Container	2166
truck	Caminhão	2206
<b>Total</b>		<b>21582</b>

## 4.8. Modelo de reconhecimento de objetos

### 4.8.1. Transfer Learning

*Transfer Learning* é uma técnica dentro de aprendizado de máquina que consiste no melhoramento do aprendizado de tarefas por meio da transferência de conhecimento adquirido pelo treinamento em uma tarefa similar (TORREY; SHAVLIK, 2010). O processo de transferência de conhecimento foi realizado por meio do carregamento dos pesos do treinamento do modelo Xception (CHOLLET, 2016) com os dados do conjunto de dados ImageNet (DENG et al., 2009).

O ImageNet consiste em um conjunto de dados com 3.2 milhões de imagens com grande diversidade de imagens, sendo um bom *milestone* para o treinamento de modelos de reconhecimento de objetos, classificação de imagens e clusterização automática de objetos (DENG et al., 2009).

Esse conjunto de dados foi escolhido para suportar o *transfer learning* porque é um conjunto vasto de imagens que permite um pré-treinamento de modelos de classificação de imagens, o problema endereçado nesta pesquisa. Além disso, o ImageNet é bem conhecido na comunidade de programadores de inteligência computacional o que permite um melhor e mais rápido entendimento e construção de modelos para sua utilização e adaptação ao problema de classificação de imagens das peças do caminhão.

### 4.8.2. Construção do Modelo

O modelo foi construído com base em uma arquitetura já existente e já implementada no Keras®, um framework do Tensor Flow®, o modelo Xception (CHOLLET, 2016). Este foi escolhido por ter a melhor relação entre performance e acurácia quando treinado com dados e validação baseado em ImageNet (KERAS, [s.d.]).

O Xception é construído com 134 camadas e 20 mil parâmetros, expostos na Tabela 10. A quantidade de parâmetros treináveis de um modelo de inteligência artificial diz quanto uma rede pode ser adaptada para um problema. No caso do Xception implementado pelo Keras, existem cerca de 9 mil parâmetros treináveis, isto é, hiper parâmetros (DATA SCIENCE ACADEMY, 2022), os quais foram adaptados por meio do treinamento do modelo para o caso específico da classificação de imagens para o modelo do caminhão.

**Tabela 10** - Quantidade de Parâmetros do modelo Xception

<b>Parâmetros</b>	<b>Quantidade</b>
Total:	20,861,480
Parâmetros Treináveis:	9,478,344
Parâmetros Não Treináveis:	11,383,136

A adaptação do modelo foi feita por meio da adição de camadas na rede para receber as imagens de entrada e permitir o treinamento adicional do Xception para a classificação de imagens do caminhão. O resumo do modelo completo, o Xception junto com as camadas adicionais está disposto na Tabela 11.

**Tabela 11** - Resumo do Modelo implementado

<b>Layer (type)</b>	<b>Output Shape</b>	<b>Param #</b>
input_1 (InputLayer)	(None, 128, 128, 3)	0
xception (Functional)	(None, 4, 4, 2048)	20,861,480
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dropout (Dropout)	(None, 2048)	0
dense (Dense)	(None, 10)	20,49

Nessa tabela, estão as camadas utilizadas para a construção do modelo, juntamente com a arquitetura Xception. O tamanho das saídas de cada camada do modelo, com um destaque para a última camada que representa a classificação entre 10 classificações possíveis para as imagens apresentadas no problema da classificação de imagens do caminhão.

O Xception é uma arquitetura de rede neural convolucional baseada em convolução separada, de forma que o modelo realiza uma *depthwise convolution*, um tipo de convolução no qual cada entrada é processada em um núcleo de processamento diferente (CHOLLET, 2016), seguido por um *pointwise convolution*, processo no qual a imagem é processada por um núcleo de processamento 1x1 fazendo uma iteração ponto a ponto de forma que cada pixel da imagem seja processado separadamente (CHOLLET, 2016).

#### 4.8.3. Ajustes do treinamento

O treinamento do modelo foi realizado com 15113 imagens separadas em 10 categorias. As imagens foram selecionadas por meio do método *Image Data Generator* da biblioteca de pré-processamento do Keras®. Pré-processamento é qualquer tratamento realizado em um

conjunto de dados (DATA SCIENCE ACADEMY, 2022). Técnicas de *Data Augmentation* também são considerados pré-processamento. Para que as imagens sejam convertidas em um formato compatível com a leitura e treinamento de modelos escritos baseados em Keras®, o método Image Data Generator foi utilizado. Este está dentro dos métodos de pré-processamento implementados pelo Keras® e foi utilizado também para a separação do conjunto de dados completo em treino e validação.

Para o correto treinamento e validação de um modelo de inteligência artificial, é interessante realizar a separação destes em um conjunto de dados de treino e um conjunto de dados de validação (DATA SCIENCE ACADEMY, 2022). A separação do conjunto de dados gerou 15113 imagens de treino e 6469 imagens de validação. A separação é necessária para que um modelo não seja validado com dados que foram utilizados para realizar seu treinamento, de forma que os resultados do modelo tenham menor incidência de vieses (DATA SCIENCE ACADEMY, 2022).

Outro ponto importante a se levar em consideração no treinamento de um modelo de inteligência artificial é a quantidade de épocas que serão utilizadas para treinar o modelo. Uma época corresponde à uma passagem completa do conjunto de dados pela rede, isto é, serão apresentadas todas as imagens do conjunto de dados de treino para a rede de forma a mostrar o que o modelo tem que aprender (DATA SCIENCE ACADEMY, 2022). Quanto mais vezes um modelo vê um conjunto de dados, isto é, quanto maior a quantidade de épocas, geralmente, maior a acurácia de treino. Isso, entretanto, não necessariamente é um bom resultado, uma vez que o modelo pode estar em um estado de super ajustamento. Isso acontece quando um modelo é muito bem adaptado para um conjunto específico de dados e, portanto, não consegue extrapolar para dados diferentes, então a acurácia de treino será muito próxima de 100%, entretanto a acurácia de validação será reduzida (Figura 24).

#### Resultado final de um modelo treinado com 100 épocas

```
Epoch 100/100
208/208 [=====] - 356s 2s/step - loss: 0.0280 - categorical_accuracy: 0.9928
```

#### Resultado da validação do modelo treinado com 100 épocas

accuracy			0.10	2838
macro avg	0.10	0.10	0.10	2838
weighted avg	0.10	0.10	0.10	2838

**Figura 24** - Comparação entre acurácia de treino e teste de um modelo treinado com 100 épocas

Para evitar a geração de um modelo em super ajustamento pela quantidade exagerada de épocas, é possível parar o treinamento utilizando um método de parada antecipada. Isso é utilizado para definir manualmente o valor de épocas de treinamento de um modelo de forma a evitar a geração de um modelo em super ajustamento, para manter o desempenho em generalização (DATA SCIENCE ACADEMY, 2022). O método de parada antecipada utilizado foi o de interrupção do treinamento no menor erro de validação, quando este para de diminuir, o treinamento do modelo é interrompido.

As métricas utilizadas para a avaliação dos resultados do modelo também são importantes para realizar a correta avaliação de sua performance. Como, no caso específico da classificação de imagens em classes distintas, temos um problema de geração de previsões categóricas, a melhor métrica para a avaliação do modelo é a acurácia categórica, portanto, a métrica escolhida para a avaliação do treinamento e da validação do modelo (Figura 24).

#### 4.8.4. Resultados do treinamento

Após todos os ajustes, o modelo foi treinado com 3 épocas. O resultado da última época de treinamento foi de 63,2% de acurácia categórica de treino, com uma perda de 0,991, já nas métricas de validação, o modelo obteve um resultado de 40,6% de acurácia categórica com um erro de 1,497 (Figura 25).

```
Epoch 1/10
473/473 [=====] - 1397s 3s/step - loss: 1.4691 - categorical_accuracy: 0.4664 - val_loss: 1.6179 - val_categorical_accuracy: 0.3441
Epoch 2/10
473/473 [=====] - 1380s 3s/step - loss: 0.9914 - categorical_accuracy: 0.6322 - val_loss: 1.4973 - val_categorical_accuracy: 0.4064
Epoch 3/10
473/473 [=====] - ETA: 0s - loss: 0.7951 - categorical_accuracy: 0.7024Restoring model weights from the end of the best epoch.
473/473 [=====] - 1355s 3s/step - loss: 0.7951 - categorical_accuracy: 0.7024 - val_loss: 1.5055 - val_categorical_accuracy: 0.4399
Epoch 00003: early stopping
Tempo de execução: 68.89 minutos
203/203 [=====] - 162s 799ms/step - loss: 1.4973 - categorical_accuracy: 0.4064
[1.497338056564331, 0.40639975666999817]
203/203 [=====] - 165s 806ms/step
```

Figura 25 - Resultados de treinamento do modelo

A avaliação de um modelo também passa pelo resultado dos testes realizados com ele. O teste de um modelo é realizado entregando imagens não utilizadas no treinamento para realizar a classificação dentro das classificações possíveis. Por meio do resultado dessas classificações é possível realizar a avaliação do modelo. As métricas utilizadas para avaliar o modelo são Precisão, *Recall* e *F1-Score*. Precisão, neste contexto, é a porcentagem de classificações corretas realizada pelo modelo dentro de uma classe específica (Equação 1).

**Equação 1** - Precisão

$$Precisão = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos positivos}}$$

O *Recall*, ou taxa de detecção, neste contexto, é a porcentagem de classificações corretas realizadas em comparação com as imagens que realmente fazem parte daquela categoria em um conjunto de dados. Isto é, a quantidade de verdadeiros positivos sobre a quantidade de verdadeiros positivos e falsos negativos para uma determinada categoria (Equação 2). Essa taxa indica a detecção correta de incidências de uma classificação na quantidade total de incidências daquela classificação.

**Equação 2** – Taxa de detecção

$$Taxa\ de\ Detecção = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos negativos}}$$

Já a métrica *F1-Score* é a média harmônica entre Precisão e *Recall* (Equação 3).

**Equação 3** - F1 Score

$$F1\ Score = 2 \frac{Precisão \times Recall}{Precisão + Recall}$$

A classe com maior precisão de classificações foi a *Container\_roof*, com 12% de precisão. Isto é, o modelo pôde prever corretamente 12% das imagens dentro de todas as imagens que foram apontadas com essa classificação. Já as que tiveram pior precisão foram *Cabin\_door* e *Container\_door* com 9% de precisão (Figura 26).

	precision	recall	f1-score	support
Cabin_roof	0.10	0.15	0.12	610
Container	0.09	0.16	0.12	609
cabin	0.11	0.09	0.10	699
cabin_door	0.09	0.06	0.07	608
cabin_ground_plate	0.10	0.10	0.10	669
container_door	0.09	0.08	0.09	607
container_roof	0.12	0.11	0.11	659
tire	0.11	0.07	0.09	698
trailer_ground_plate	0.11	0.13	0.12	649
truck	0.10	0.06	0.08	661
accuracy			0.10	6469
macro avg	0.10	0.10	0.10	6469
weighted avg	0.10	0.10	0.10	6469

**Figura 26** - Resultados do teste do modelo

Em relação à taxa de detecção, a classe com a melhor performance dessa métrica foi o Container com 16% de verdadeiros positivos em relação a todas as incidências de Container (Figura 26). Isso indica que, apesar de ter uma quantidade grande de classificações erradas realizadas como container, essa classificação foi menos apontada do que as demais pelas outras classes.

A média harmônica é uma junção da precisão e da taxa de detecção para entregar um indicador único de performance por classe. Essa média reflete melhor o desbalanceamento entre as duas métricas. Os valores apontados pela média harmônica variam entre 7 e 12% nos resultados desse modelo (Figura 26).

Outra forma de avaliar os resultados do treinamento de uma rede neural é por meio da matriz de confusão (Figura 27).

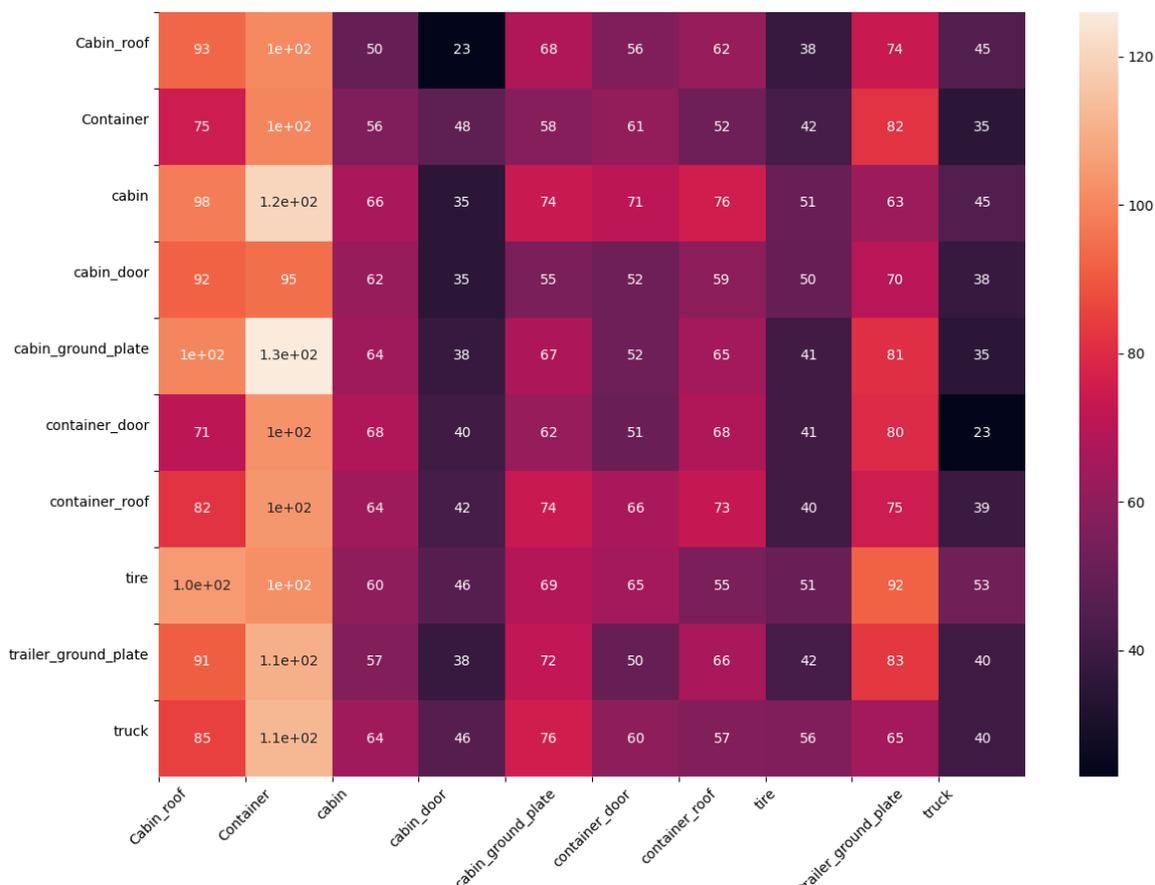


Figura 27 - Matriz de confusão com os resultados do modelo

A matriz de confusão recebe esse nome porque cruza o resultado das classificações com a classificação real de cada indivíduo. Cada valor na diagonal principal da matriz representa os verdadeiros positivos, isto é, a quantidade de classificações corretas feitas pelo modelo para uma determinada classe. Nesse caso, a classe com a maior quantidade de verdadeiros positivos foi o Container com 100 verdadeiros positivos. O modelo classificou corretamente 659 imagens no total (Tabela 12), isso está de acordo com o resultado obtido de acurácia geral do modelo (Figura 26) de 10% uma vez que foram utilizadas 6469 imagens de validação (Figura 26).

Tabela 12 - Quantidade de verdadeiros positivos por classe

Classe	Peça Correspondente	Quantidade de Verdadeiros Positivos
cabin	Cabine	66
cabin_door	Porta Lateral	35

cabin_ground_plate	Plataforma da Cabine	67
Cabin_roof	Teto da Cabine	93
Container	Container	100
container_door	Porta do Container	51
container_roof	Teto do Container	73
tire	Rodas	51
trailer_ground_plate	Plataforma do Container	83
truck	Caminhão	40
<b>Total</b>		<b>659</b>

Os falsos positivos estão representados em todos os outros campos da matriz. As linhas representam as classificações verdadeiras e as colunas representam as classificações previstas pelo modelo. Por exemplo, 130 imagens de Cabin\_ground\_plate foram classificadas erroneamente como Container. Como uma forma de entender como as métricas de Precisão e Taxa de detecção são calculadas, a Precisão compara o valor de verdadeiro positivo com o restante da sua coluna e a Taxa de detecção compara o valor de verdadeiro positivo com o restante de sua linha, seguindo o exemplo do container, ao avaliar os resultados expostos na matriz de confusão (Figura 27) é possível verificar os valores obtidos em Precisão (9%) e Taxa de Detecção (16%) (Figura 26).

## 5 CONCLUSÃO

*Nesta secção são apresentadas as principais conclusões a respeito deste Projeto de Graduação. Nela, também são traçados planos para o conteúdo da próxima etapa do estudo.*

A qualidade é um aspecto integrado à avaliação de um produto seja por parte da garantia da qualidade, seja pela percepção dos consumidores de um produto sobre as características deste. Existem formas diversas de garantir a qualidade em uma linha de montagem e formas diferentes de construir um sistema de inteligência computacional. A combinação destes pode apoiar no controle de qualidade de acordo com a perspectiva adotada no planejamento do controle de qualidade.

Sob a ótica da inovação e das tecnologias dispostas na manufatura, a indústria 4.0 define a utilização de tecnologias inteligentes que apoiam o desenvolvimento da manufatura com melhor eficiência e produtividade, seja por parte de um operador humano, seja por meio da utilização de sistemas de apoio físico, com o uso de tecnologias de robótica para a realização das tarefas.

Um AAS pode ser construído de formas diferentes. Este tipo de sistema garante o apoio a uma montagem, apoio esse que pode ser físico ou informacional. A construção de um AAS pode ou não conter uma inteligência em sua arquitetura, mas se trata de um sistema cyber físico, onde existe uma interação entre o mundo real e o mundo virtual. Uma inteligência artificial que utiliza sensores para detectar dados de uma linha de montagem para realizar um processamento para entendimento das possíveis melhorias que podem ocorrer em um determinado instante da montagem e informá-los para um operador humano é, por definição, um tipo de AAS informacional, uma vez que realiza uma interação mundo real mundo virtual para fornecer informações relevantes a um operador de forma a apoiar um processo de montagem.

Ainda, existem construções diferentes de algoritmos inteligentes para tratar diferentes formas de avaliar e controlar a qualidade de um processo. Dessa forma, é possível a adaptação da tecnologia para adequação dos sistemas inteligentes às expectativas e peculiaridades de uma linha de montagem em específico.

Portanto, utilizar tecnologias de inteligência artificial para garantir a qualidade do processo de montagem é uma forma de adequação de uma linha de manufatura tradicional à quarta revolução industrial por meio da transformação digital da montagem. Dessa forma, estudar formas de desenvolver e implementar um protótipo de AAS em uma linha de montagem tradicional pode ser um meio de contribuir para o desenvolvimento tecnológico de empresas do setor industrial e adequação à indústria 4.0.

A criação de um sistema de assistência à montagem primeiro passa pela definição do tipo de assistência fornecida pelo sistema e pelo tipo de construção deste. Definindo um sistema como digital, este enfrenta um desafio de virtualizar o processo de montagem para a melhor compreensão do processo por parte do sistema e evitar dessincronização entre o processo realizado pelo operador e o processo identificado pelo sistema.

A utilização de grafos para virtualizar as informações de montagem do mundo real torna o reconhecimento do estado do processo pelo sistema, o qual pode ser realizado por meio de sensores e por meio de algoritmos inteligentes baseados em reconhecimento de imagens, como o utilizado pelo projeto AuQua, mais eficiente. Isso pode ajudar na diminuição do tempo de processamento da identificação e sincronização do estado de montagem real e reconhecido pelo sistema.

O grafo desenvolvido é específico para o processo de montagem do protótipo do caminhão como forma de testar a implementação de um grafo para o ganho de eficiência na sincronização do sistema com a montagem real.

Existem, entretanto, melhorias possíveis para o grafo desenvolvido. Uma próxima etapa desse estudo compreende a inclusão dos valores de precisão da identificação do estado realizada pelo sistema. Além dessa, outras próximas etapas são possíveis, como a criação de outras estruturas de grafos que correspondem outros inícios para o processo, alterando toda a lógica sequencial do grafo. Ainda, é possível desenvolver a estruturação de grafos de formas diferentes com os nós representando outros aspectos da montagem que não os estados. Bem como, outra etapa viável é o desenvolvimento de um programa generalista que permite a criação de um grafo para qualquer processo de montagem.

Este trabalho também entrega como resultado um algoritmo de geração de conjunto de imagens geradas a partir de arquivos stl, de forma automática e em acordo com a literatura especializada na área. O que pode ser útil para a criação de dados de treinamento para outros problemas em fase de prototipação com estrutura de dados semelhantes.

Ainda, o trabalho mostra que é possível utilizar este conjunto de dados gerado para realizar o treinamento de modelos de inteligência artificial.

Uma segunda etapa para esse estudo é a avaliação do ganho de eficiência de sistemas de assistência à montagem inteligentes com a implementação da virtualização de processos de montagem por meio de grafos de conhecimento, contribuindo para o avanço do

desenvolvimento de sistemas de assistência à montagem industrial para garantia e controle de qualidade na execução desses processos. Outro ponto interessante de melhoria para uma segunda etapa do projeto é o melhoramento dos resultados de treinamento do modelo por meio da melhoria do conjunto de dados, e outros ajustes nos hiper parâmetros da arquitetura implementada e desenvolvida.

## REFERÊNCIAS BIBLIOGRÁFICAS

ARCENALES-CARRION, R. et al. **Management Tools for Process Mapping and Modeling in Assembly Industry**. Congress in Sustainability, Energy and City. **Anais...**2022.

AUGUSTAUSKAS, R.; LIPNICKAS, A.; SURGAILIS, T. Segmentation of drilled holes in texture wooden furniture panels using deep neural network. **Sensors**, v. 21, n. 11, 1 jun. 2021.

BERGER, C. et al. **Characterization of Cyber-Physical Sensor Systems**. Procedia CIRP. **Anais...**Elsevier B.V., 2016.

BEZERRA, D. G. DE S. et al. **Artificial Intelligence Applications for Defect Detections in Industrial Processes: a Bibliometric Analysis**. International Joint Conference on Industrial Engineering and Operations Management, 17 jul. 2023. DOI: [10.14488/IJCIEOM2023\\_FULL\\_0037\\_37762](https://doi.org/10.14488/IJCIEOM2023_FULL_0037_37762)

BHANDARI, B.; PARK, G. Development of a surface roughness evaluation method from light and shade composition using deep learning. 2021.

BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. 22 abr. 2020.

CHEN, Z. et al. Assembly Information Model Based on Knowledge Graph. **Journal of Shanghai Jiaotong University (Science)**, v. 25, n. 5, p. 578–588, 1 out. 2020.

CHOLLET, F. Xception: Deep Learning with Depthwise Separable Convolutions. 7 out. 2016.

CNI - CONFEDERAÇÃO NACIONAL DA INDÚSTRIA. **Confederação Nacional da Indústria**. Disponível em: <<https://www.portaldaindustria.com.br/cni/>>. Acesso em: 16 mar. 2024.

CORRÊA, F. et al. Maturity in Knowledge Management: practical application of a method. **Transinformacao**, v. 34, 2022.

DA SILVA, I. A. et al. Industry 4.0 Readiness: a new framework for maturity evaluation based on a bibliometric study of scientific articles from 2001 to 2020. **DYNA (Colombia)**, v. 88, n. 218, p. 101–109, 1 jul. 2021. DOI: <https://doi.org/10.7440/res64.2018.03>

DA SILVEIRA BRUNO, F. **A quarta revolução industrial do setor têxtil e de confecção**. 1. ed. São Paulo: Estação das Letras e Cores, 2016.

DATA SCIENCE ACADEMY. **Deep Learning Book**. [s.l.: s.n.].

DAUDA, K. Development and Modeling of Decision Tree for Survival Data with Multiple Events Using Deviance and Cox-Snell Residuals within Node Homogeneity Technique. **International Journal of Advanced Health Science and Technology**, v. 2, n. 3, p. 183–190, 15 jun. 2022.

DE QUEIROZ, D. C. F. et al. Machine Learning Applied to Industrial Assembly Lines: A Bibliometric Study. Em: DOS REIS, J. C. G.; FREIRES, F. G. M.; JUNIOR, M. V. (Eds.). **International Joint conference on Industrial Engineering and Operations Management**. [s.l.] Springer Proceedings in Mathematics & Statistics, vol 431. Springer, Cham., 2023. v. 431p. 509–520. DOI: [10.1007/978-3-031-47058-5\\_39](https://doi.org/10.1007/978-3-031-47058-5_39)

DENG, J. et al. **ImageNet: A large-scale hierarchical image database**. 2009 IEEE Conference on Computer Vision and Pattern Recognition. **Anais...IEEE**, jun. 2009.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Escala de maturidade tecnológica TRL/MRL.**

ESPINOSA, R.; PONCE, H.; GUTIÉRREZ, S. Click-event sound detection in automotive industry using machine/deep learning. **Applied Soft Computing**, v. 108, 1 set. 2021.

FELIPPES, B. et al. 3D-CUBE readiness model for industry 4.0: technological, organizational, and process maturity enablers. **Production and Manufacturing Research**, v. 10, n. 1, p. 875–937, 2022.

FERNANDES, F. C. F.; FILHO, M. G. **Planejamento e controle da produção: dos fundamentos ao essencial**. 1. ed. São Paulo: Atlas, 2019.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow**. 3. ed. [s.l.] O Reilly Media Inc., 2022.

GIANNECCHINI, I. C. G. **Truck Images**. Disponível em: <<https://github.com/isabelcgomes/truckImages>>. Acesso em: 17 ago. 2024.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. 1. ed. [s.l.] MIT Press, 2016.

HE, K. et al. **Deep Residual Learning for Image Recognition**. [s.l.: s.n.]. Disponível em: <<http://image-net.org/challenges/LSVRC/2015/>>.

HINRICHSEN, S.; RIEDIGER, D.; UNRAU, A. **ASSISTANCE SYSTEMS IN MANUAL ASSEMBLY**. Production Engineering and Management. **Anais...Lemgo**, Germany: 2016.

HOGAN, A. et al. Knowledge graphs. **ACM Computing Surveys**, v. 54, n. 4, 1 jul. 2021.

IEAMSAARD, J.; SANDNES, F. E.; MUNEESAWANG, P. Reducing False Detection during Inspection of HDD using Super Resolution Image Processing and Deep Learning. 2017.

IQBAL, R. et al. Fault Detection and Isolation in Industrial Processes Using Deep Learning Approaches. **IEEE Transactions on Industrial Informatics**, v. 15, n. 5, p. 3077–3084, 1 maio 2019.

JWO, J. S. et al. Intelligent system for railway wheelset press-fit inspection using deep learning. **Applied Sciences (Switzerland)**, v. 11, n. 17, 1 set. 2021.

KERAS. **Keras Applications**. Disponível em: <<https://keras.io/api/applications/#usage-examples-for-image-classification-models>>. Acesso em: 23 ago. 2024.

KIM, H. et al. Broken stitch detection method for sewing operation using CNN feature map and image-processing techniques. **Expert Systems with Applications**, v. 188, 1 fev. 2022.

KLINGENBERG, C. **Industry 4.0: what makes it a revolution?** [s.l: s.n.]. Disponível em: <<https://www.researchgate.net/publication/319127784>>.

KOVILPILLAI, J. J. A.; JAYANTHY, S. An optimized deep learning approach to detect and classify defective tiles in production line for efficient industrial quality control. **Neural Computing and Applications**, v. 35, n. 15, p. 11089–11108, 1 maio 2023.

LE, H. F.; ZHANG, L. J.; LIU, Y. X. Surface Defect Detection of Industrial Parts Based on YOLOv5. **IEEE Access**, v. 10, p. 130784–130794, 2022.

LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, nov. 1998.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep learning**. Nature Nature Publishing Group, , 27 maio 2015.

LEI, H.-W. et al. **Defect Detection for Polymeric Polarizer Based on Faster R-CNN** *Journal of Information Hiding and Multimedia Signal Processing* c. [s.l: s.n.].

LIU, G. et al. Chassis assembly detection and identification based on deep learning component instance segmentation. **Symmetry**, v. 11, n. 8, 2019.

LIU, M. et al. A Knowledge Graph-Based Approach for Assembly Sequence Recommendations for Wind Turbines. **Machines**, v. 11, n. 10, 1 out. 2023.

LU, H. et al. A state-classification approach for light-weight robotic drilling using model-based data augmentation and multi-level deep learning. **Mechanical Systems and Signal Processing**, v. 167, 15 mar. 2022.

LUGER, G. F. **Artificial Intelligence**. 6. ed. New Mexico: Pearson, 2009.

MAYS, R. G. et al. **Experiences with Defect Prevention**. [s.l: s.n.].

MCCULLOCH, W. S.; PITTS, W. **A LOGICAL CALCULUS OF THE IDEAS IMMANENT IN NERVOUS ACTIVITY** *BULLETIN OF MATHEMATICAL BIOPHYSICS*. [s.l: s.n.].

MIRJALILI, S. Genetic Algorithm. Em: **Evolutionary Algorithms and Neural Networks**. 1. ed. [s.l.] Springer, Cham, 2019. v. 780p. 43–55.

MITCHELL, T. **Machine Learning**. [s.l.] McGraw-Hill Science/Engineering/Math, 1997.

MUELLER, R.; HOERAUF, L.; BASHIR, A. **Assembly process prediction with digital assistance systems to ensure synchrony between digital and physical product state using recurrent neural networks**. 2020 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA). **Anais...IEEE**, set. 2020.

MUMUNI, A.; MUMUNI, F. **Data augmentation: A comprehensive survey of modern approaches**. **ArrayElsevier B.V.**, , 1 dez. 2022.

MUSHTAQ, F. et al. Nuts&bolts: YOLO-v5 and image processing based component identification system. **Engineering Applications of Artificial Intelligence**, v. 118, 1 fev. 2023a.

MUSHTAQ, F. et al. Nuts&bolts: YOLO-v5 and image processing based component identification system. **Engineering Applications of Artificial Intelligence**, v. 118, 1 fev. 2023b.

NIKOLENKO, A. et al. Digital Assembly Assistance Systems – A Case Study. Em: [s.l: s.n.]. p. 24–33.

ORTT, R.; STOLWIJK, C.; PUNTER, M. **Implementing Industry 4.0: assessing the current state**. **Journal of Manufacturing Technology Management**Emerald Group Holdings Ltd., , 18 nov. 2020.

PACK KAEHLING, L. et al. **Reinforcement Learning: A Survey****Journal of Artificial Intelligence Research**. [s.l: s.n.].

PATRIZI, A.; GAMBOSI, G.; ZANZOTTO, F. M. Data augmentation using background replacement for automated sorting of littered waste. **Journal of Imaging**, v. 7, n. 8, 1 ago. 2021.

PYTHON SOFTWARE FOUNDATION. **Python Organization**. Disponível em: <<https://www.python.org/>>. Acesso em: 10 jun. 2024.

REDMON, J. et al. You Only Look Once: Unified, Real-Time Object Detection. 8 jun. 2015.

RIEDEL, A. et al. A deep learning-based worker assistance system for error prevention: Case study in a real-world manual assembly. **Advances in Production Engineering And Management**, v. 16, n. 4, p. 393–404, 1 dez. 2021.

ROZENFELD, H. et al. **Gestão de Desenvolvimento de Produtos**. 1. ed. [s.l.] Editora Saraiva, 2006.

SASSI, P.; TRIPICCHIO, P.; AVIZZANO, C. A. A smart monitoring system for automatic welding defect detection. **IEEE Transactions on Industrial Electronics**, v. 66, n. 12, p. 9641–9650, 1 dez. 2019.

SCHAEFFER, S. E. Graph clustering. **Computer Science Review**, v. 1, n. 1, p. 27–64, ago. 2007.

SCHWEBIG, A. I. M.; TUTSCH, R. Compilation of training datasets for use of convolutional neural networks supporting automatic inspection processes in industry 4.0 based electronic manufacturing. **Journal of Sensors and Sensor Systems**, v. 9, n. 1, p. 167–178, 1 jul. 2020a.

SCHWEBIG, A. I. M.; TUTSCH, R. Intelligent fault detection of electrical assemblies using hierarchical convolutional networks for supporting automatic optical inspection systems. **Journal of Sensors and Sensor Systems**, v. 9, n. 2, p. 363–374, 2 nov. 2020b.

SHAFI, I. et al. Deep Learning-Based Real Time Defect Detection for Optimization of Aircraft Manufacturing and Control Performance. **Drones**, v. 7, n. 1, 1 jan. 2023.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on Image Data Augmentation for Deep Learning. **Journal of Big Data**, v. 6, n. 1, 1 dez. 2019.

SILVA, E. L. DA; MENEZES, E. M. **Metodologia da Pesquisa e Elaboração de Dissertação**. 3. ed. [s.l: s.n.].

SIMONE, F. et al. Managing Industrial Automation: How Knowledge Graphs Can Boost Production. Em: [s.l: s.n.], p. 312–320.

SOUZA, V. L. L.; BARBALHO, S. C. M. EXPLORANDO O USO DO BPMN PARA MAPEAR A IMPLEMENTAÇÃO DE INTELIGÊNCIA ARTIFICIAL E REALIDADE AUMENTADA EM LINHAS DE MONTAGEM: UM ESTUDO DO PROCESSO DE MONTAGEM DO TRUCK. In: **14o congresso brasileiro de inovacao e gestao de desenvolvimento de produto**, 2023, Natal. Anais do Congresso Brasileiro de Inovação e Gestão de Desenvolvimento do Produto. Natal: Instituto Metrópole Digital (IMD), 2023.

SWART, P. et al. **Exploring Network Structure, Dynamics, and Function Using NetworkX**. [s.l: s.n.]. Disponível em: <[http://conference.scipy.org/proceedings/SciPy2008/paper\\_2](http://conference.scipy.org/proceedings/SciPy2008/paper_2)>.

TARTUCE, T. J. A. **Métodos de pesquisa**. [s.l.] Fortaleza: UNICE – Ensino Superior, 2006.

TEALE, D. C. **New Frontiers in Manufacturing**. [s.l.] Springer Berlin Heidelberg, 1987.

THAMM, S. et al. **Concept for an augmented intelligence-based quality assurance of assembly tasks in global value networks**. *Procedia CIRP. Anais...Elsevier B.V.*, 2020.

TOLEDO, J. C. DE et al. **Qualidade: gestão e métodos**. 1. ed. [s.l.] Livros Técnicos e Científicos Editora, 2014.

TORKUL, O.; SELVI, İ. H.; ŞIŞCI, M. Smart seru production system for Industry 4.0: a conceptual model based on deep learning for real-time monitoring and controlling. **International Journal of Computer Integrated Manufacturing**, 2022.

TORREY, L.; SHAVLIK, J. Transfer Learning. Em: **Handbook of Research on Machine Learning Applications and Trends**. [s.l.] IGI Global, 2010. p. 242–264.

VANDEWINCKELE, L. et al. Overview of artificial intelligence-based applications in radiotherapy: Recommendations for implementation and quality assurance. **Radiotherapy and Oncology**, n. 153, p. 55–66, 2020.

WANG, L. et al. Digital-twin deep dynamic camera position optimisation for the V-STARS photogrammetry system based on 3D reconstruction. **International Journal of Production Research**, 2023.

WANG, Y. Serial Number Recognition of Ceramic Membrane Based on End-to-end Deep Learning. **Computer-Aided Design and Applications**, v. 21, n. S1, p. 232–245, 2024.

YAO, Z. et al. An Aircraft Assembly System Based on Improved YOLOv5. Em: [s.l: s.n.]. p. 18–28.

YOSINSKI, J. et al. How transferable are features in deep neural networks? 6 nov. 2014.

ZAMORA-HERNÁNDEZ, M. A. et al. Deep learning-based visual control assistant for assembly in Industry 4.0. **Computers in Industry**, v. 131, 1 out. 2021.

ZHANG, C. et al. ZJU-Leaper: A Benchmark Dataset for Fabric Defect Detection and a Comparative Study. **IEEE Transactions on Artificial Intelligence**, v. 1, n. 3, p. 219–232, 1 dez. 2020.

ZHANG, X.; WANG, G. Stud Pose Detection Based on Photometric Stereo and Lightweight YOLOv4. **Journal of Artificial Intelligence and Technology**, v. 2, n. 1, p. 32–37, 25 jan. 2022.

ZHOU, C. et al. Green Plums Surface Defect Detection Based on Deep Learning Methods. **IEEE Access**, v. 10, p. 100397–100407, 2022.

ZHOU, L.; ZHANG, L.; KONZ, N. Computer Vision Techniques in Manufacturing. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 53, n. 1, p. 105–117, 1 jan. 2023.