

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

YURI EMANOEL PEREIRA DIAS

**IMPLEMENTAÇÃO DE MONITORAMENTO INTELIGENTE PARA DETECÇÃO E
CLASSIFICAÇÃO DE DEFEITOS SUPERFICIAIS EM PRÉ-FORMAS OBTIDAS
POR MANUFATURA ADITIVA POR DEPOSIÇÃO A ARCO**

CAMPINA GRANDE – PB

2025

YURI EMANOEL PEREIRA DIAS

**IMPLEMENTAÇÃO DE MONITORAMENTO INTELIGENTE PARA DETECÇÃO E
CLASSIFICAÇÃO DE DEFEITOS SUPERFICIAIS EM PRÉ-FORMAS OBTIDAS POR
MANUFATURA ADITIVA POR DEPOSIÇÃO A ARCO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Campina Grande em nível de mestrado, em cumprimento às exigências legais como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Walman Benício de Castro.

Coorientador: Prof. Dr. Jefferson Segundo de Lima

CAMPINA GRANDE – PB

2025

D541i Dias, Yuri Emanuel Pereira.

Implementação de monitoramento inteligente para detecção e classificação de defeitos superficiais em pré-formas obtidas por manufatura aditiva por deposição a arco / Yuri Emanuel Pereira Dias. – Campina Grande, 2025.

77 f. : il. color.

Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Campina Grande, Centro de Ciências e Tecnologia, 2025.

“Orientação: Prof. Dr. Walman Benício de Castro, Prof. Dr. Jefferson Segundo de Lima”.

Referências.

1. Processos Mecânicos Metalúrgicos (PMM). 2. Manufatura Aditiva por Deposição a Arco (MADA). 3. Aprendizado de Máquina – Modelo YOLO. 4. Rede Neural. 5. Processo de Classificação e Reconhecimento. I. Castro, Walman Benício de. II. Lima, Jefferson Segundo de. III. Título.

UFCG/BC

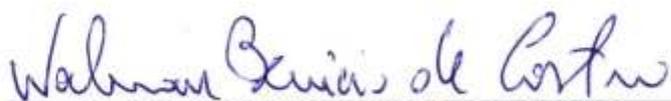
CDU 621:669(043.3)

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECÁRIA SEVERINA SUELI DA SILVA OLIVEIRA CRB-15/225

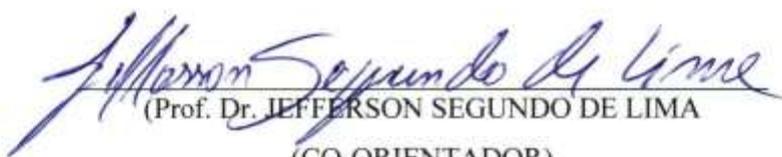
**IMPLEMENTAÇÃO DE MONITORAMENTO INTELIGENTE PARA DETECÇÃO E
CLASSIFICAÇÃO DE DEFEITOS SUPERFICIAIS EM PRÉ-FORMAS OBTIDAS POR
MANUFATURA ADITIVA POR DEPOSIÇÃO A ARCO**

YURI EMANOEL PEREIRA DIAS

Dissertação Aprovada em 26/02/2025 pela Banca Examinadora constituída dos seguintes membros:



Prof. Dr. WALMAN BENICIO DE CASTRO
(ORIENTADOR)



(Prof. Dr. JEFFERSON SEGUNDO DE LIMA
(CO-ORIENTADOR)



Prof. Dr. RAPHAEL HENRIQUE FALCÃO DE MELO
(EXAMINADOR INTERNO)



Prof. Dr. SÉRGIO NATAN SILVA
(EXAMINADOR EXTERNO)

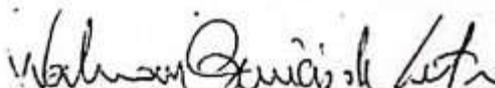


UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE CIÊNCIAS E TECNOLOGIA
UNIDADE ACADÊMICA DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

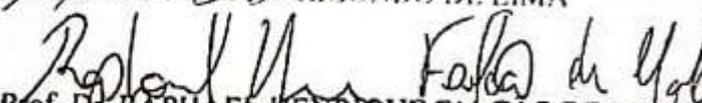


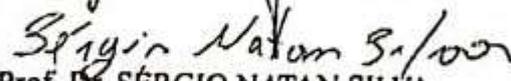
ATA DA CENTÉSIMA SEXAGÉSIMA PRIMEIRA DEFESA PARA CONCESSÃO DE GRAU DE MESTRE EM ENGENHARIA MECÂNICA, REALIZADA EM 26 DE FEVEREIRO DE 2025 (Nº 161).

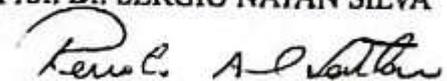
CANDIDATO(A): YURI EMANOEL PEREIRA DIAS; COMISSÃO EXAMINADORA: Prof. Dr. WALMAN BENICIO DE CASTRO (UFPG/CCT/UAEM/PPGEM - Orientador); Prof. Dr. JEFFERSON SEGUNDO DE LIMA (IFRN - Coorientador - Externo); Prof. Dr. RAPHAEL HENRIQUE FALCÃO DE MELO (IFPB - Examinador Interno); Prof. Dr. SÉRGIO NATAN SILVA (UFPG/CBEEI/UAEE Examinador Externo), ÁREA DE CONCENTRAÇÃO: Processos Mecânico-Metalúrgicos, HORA DE INÍCIO: 14h; LOCAL: UFPG - CAMPINA GRANDE - PB. O(a) candidato(a) foi arguido oralmente pelos membros da Comissão Examinadora, tendo demonstrado suficiência de conhecimento e capacidade de sistematização no tema de sua dissertação, sendo APROVADO(A). Face à aprovação, declaram os membros da Comissão, achar o(a) candidato(a), após o cumprimento das referidas exigências, legalmente habilitado a receber o Grau de Mestre em Engenharia Mecânica, cabendo a Universidade Federal de Campina Grande, como direito, providenciar a expedição do Diploma, a que o(a) mesmo(a) faz jus. Na forma regulamentar, foi lavrada a presente ata, que é assinada por mim, Thiago Pereira Fernandes, Secretário do Mestrado em Engenharia Mecânica e os membros da Comissão Examinadora presentes. Campina Grande, 26 de fevereiro de 2025.


Prof. Dr. WALMAN BENICIO DE CASTRO


Prof. Dr. JEFFERSON SEGUNDO DE LIMA


Prof. Dr. RAPHAEL HENRIQUE FALCAO DE MELO


Prof. Dr. SÉRGIO NATAN SILVA


Prof. Dr. RENATO ALEXANDRE COSTA DE SANTANA – Coordenador do PPGEM/UFPG


THIAGO PEREIRA FERNANDES – Secretário do PPGEM


YURI EMANOEL PEREIRA DIAS

*Aos meus pais Maria Alderiza de Assis
Pereira e José Uelinton de Assis Pereira e a
minha Avó Valderi.*

CONTRIBUIÇÕES INTELECTUAIS DURANTE O PERÍODO DE MESTRADO

A primeira contribuição é referente a apresentação em Congresso de resultados parciais do algoritmo e da IHM.

- *Detecção e classificação de defeitos superficiais Através de rede neural convolucional em pré-formas de Aço inoxidável 316l-si obtidas por MADA. Evento: CONEM 2024. DOI: 10.26678/ABCM.CONEM2024.CON24-1144*

Por último, a segunda contribuição diz respeito à registros de softwares e modelo de utilidade criados tanto para IHM desta dissertação, quanto para outro código criado para o aumento de banco de dados.

- *Registro de software depositado: Ferramenta computacional baseada em YOLO v8 para detecção e classificação de defeitos superficiais offline e em vídeo de pré-formas. Com número de processo 512025000161-4.*
- *Modelo de Utilidade Depositado: Ferramenta computacional baseada em YOLO v8 para detecção e classificação de defeitos superficiais offline e em vídeo de pré-formas. Com Número de Processo BR 20 2025 000181-6.*
- *Registro de software depositado: Ferramenta para aumento artificial de banco de dados de imagem. Com número de registro BR512024005152-0.*

AGRADECIMENTOS

Em primeiro lugar, gostaria de expressar minha gratidão a Deus pela força e apoio nos dias difíceis. Agradeço aos meus pais José Ueliton de Assis Pereira e Maria Alderiza Dias Pereira pela fé, confiança e apoio nesse período, sempre apoiando e estando ao meu lado nas decisões. Agradeço também, a todos os familiares restantes, que ajudaram direta ou indiretamente nesta caminhada.

Um agradecimento especial ao meu grande amigo Júlio Feitosa da Silva Neto pelo valioso apoio no desenvolvimento de atividades experimentais e computacionais. Sua colaboração enriqueceu tanto minha experiência pessoal quanto a acadêmica. Um agradecimento especial para meus amigos e colaboradores do Laboratório de Soldagem (LabSol)

Um agradecimento ao meu orientador, Prof. Dr. Walman Benício de Castro, cuja sabedoria e apoio constante me guiaram durante esta jornada. Da mesma forma, sou grato ao meu amigo e coorientador, Prof. Dr. Jefferson Segundo de Lima, por suas valiosas contribuições ao longo de todo o processo de pesquisa.

Agradeço à Fundação de Apoio à Pesquisa do Estado da Paraíba (FAPESQ) pela concessão da bolsa de estudos (processo nº 300409/2023-0) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo custeio de equipamentos essenciais ao desenvolvimento desta pesquisa (processo nº 409585/2022-0). A oportunidade e o apoio fornecidos pela FAPESQ e CNPq facilitaram minha jornada acadêmica, e também reforçaram meu compromisso com a ciência e a tecnologia no país.

Por fim, agradeço a todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho. Cada um de vocês foi parte essencial desta caminhada, e minha gratidão é imensa por cada gesto de apoio e encorajamento.

“Demore o tempo que for para decidir o que você quer da vida, e depois que decidir não recue ante nenhum pretexto”

Friedrich Nietzsche

“Que Deus me dê serenidade para aceitar as coisas que não posso mudar, coragem para mudar as que posso mudar e sabedoria para distinguir uma da outra”

Reinhold Niebuhr

YURI EMANOEL PEREIRA DIAS

**IMPLEMENTAÇÃO DE MONITORAMENTO INTELIGENTE PARA DETECÇÃO E
CLASSIFICAÇÃO DE DEFEITOS SUPERFICIAIS EM PRÉ-FORMAS OBTIDAS
POR MANUFATURA ADITIVA POR DEPOSIÇÃO A ARCO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Campina Grande em nível de mestrado, em cumprimento às exigências legais como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica.

YURI EMANOEL PEREIRA DIAS

**IMPLEMENTAÇÃO DE MONITORAMENTO INTELIGENTE PARA DETECÇÃO E
CLASSIFICAÇÃO DE DEFEITOS SUPERFICIAIS EM PRÉ-FORMAS OBTIDAS
POR MANUFATURA ADITIVA POR DEPOSIÇÃO A ARCO**

Dissertação apresentada e aprovada em ___/___/___, pela seguinte Banca Examinadora:

BANCA EXAMINADORA

Prof. Dr. Walman Benício de Castro - Orientador
Universidade Federal de Campina Grande (UFCG)

Prof. Dr. Jefferson Segundo de Lima - Coorientador
Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
(IFRN)

Prof. Dr. Raphael Henrique Falcão de Melo- Avaliador Interno
Universidade Federal de Campina Grande (UFCG)

Prof. Sérgio Natan Silva- Avaliador Externo
Universidade Federal de Campina Grande (UFCG)

RESUMO

No momento em que se fala de flexibilidade somado a uma rapidez de produção e economia de material, é bem sabido que tais características fazem da Manufatura Aditiva (MA), conhecida como impressão 3D, ganhar destaque na indústria. Dentre os processos de MA de metais, a Manufatura Aditiva por Deposição a Arco (MADA) se utiliza de um arco elétrico com fonte de calor para possibilitar a fusão do material, o que gera uma alta eficiência de deposição e a possibilidade de operação automatizada com um baixo custo. Em contraste, o repetitivo aquecimento pela sobreposição de camadas e o calor excessivo gerado na MADA podem levar a geração de defeitos, tais como alto nível de tensões residuais trativas, distorções, acabamento superficial prejudicado, desestabilização da geometria de deposição ao longo das camadas, além de rugosidade superficial e porosidade. Assim, modelos de redes neurais para controle visual estão sendo cada vez mais usados nas linhas de produção para atendimento da demanda por alta qualidade nos produtos fabricados. Por conseguinte, este trabalho teve como objetivo a implementação de um monitoramento *in situ* de defeito superficiais de porosidade, *humping* e respingos em paredes finas fabricadas por MADA, através da aplicação de Aprendizado de Máquina por meio do modelo *YOLO (You Only Look Once)*. O processo de classificação e reconhecimento foi validado por meio de comparação com resultados obtidos de forma manual e aplicado através de uma interface gráfica com o usuário concebida com algoritmos em *Python*. Utilizando-se do modelo pré-treinado *YOLOv8n*, disponível no site da *ultralitics*, foi possível fazer o treinamento com aprendizado por transferência. O treinamento foi realizado com 300 épocas em três modelos diferentes, B1, B2 e B3 que diferiam em quantidade de imagens. Através das técnicas de aumento artificial, foi possível ampliar a quantidade dos bancos de dados para uma melhor performance. Além disso, foi aplicado a técnica de *tuning*, que utiliza combinações de hiperparâmetros para encontrar uma configuração ideal para o modelo. Para o entendimento da efetividade da rede foram aplicados os conceitos de métricas de avaliação e matriz de confusão empregados foram os seguintes: *mAP*, *Recall*, *Precision*. Através da análise dos resultados obteve-se que o banco B1 obteve melhor performance geral na detecção de defeitos, obtendo 74.5% para precisão, 61.2%, *recall*, 65,7% para o *mAP* e 71,5 % para o modelo. De forma geral a rede

neural concebida no algoritmo se mostrou uma ferramenta em potencial para classificação e localização de defeitos.

Palavras-chave: Manufatura Aditiva por Deposição a Arco, Aprendizado de Máquina, Rede Neural, YOLO, Monitoramento *IN-SITU*, Classificação e Reconhecimento.

ABSTRACT

At a time when flexibility, combined with production speed and material economy, it is well known that such characteristics make Additive Manufacturing (AM), also known as 3D printing, gain prominence in the industry. Among metal AM processes, Wire Arc Additive Manufacturing (WAAM) uses an electric arc as a heat source to enable material fusion, which generates high deposition efficiency and the possibility of automated operation at a low cost. In contrast, repetitive heating by layer superposition and excessive heat generated in WAAM can lead to the generation of defects such as high levels of tensile residual stresses, distortions, poor surface finish, destabilization of deposition geometry along the layers, as well as surface roughness and porosity. Thus, neural network models for visual control are increasingly being used in production lines to meet the demand for high-quality manufactured products. Consequently, this work aimed to implement in-situ monitoring of surface defects such as porosity, humping, and spatters in thin walls manufactured by WAAM, through the application of Machine Learning using the YOLO (You Only Look Once) model. The classification and recognition process was validated by comparison with manually obtained results and applied through a graphical user interface designed with Python algorithms. Using the pre-trained YOLOv8n model, available on the Ultralytics website, it was possible to perform training with transfer learning. The training was carried out for 300 epochs in three different models, B1, B2, and B3, which differed in the quantity of images. Through artificial augmentation techniques, it was possible to expand the amount of data in the databases for better performance. In addition, the tuning technique was applied, which uses combinations of hyperparameters to find an ideal configuration for the model. For understanding the effectiveness of the network, the concepts of evaluation metrics and confusion matrix were applied, specifically mAP, Recall, and Precision. Through the analysis of the results, it was obtained that database B1 achieved the best overall performance in defect detection, with 74.5% for precision, 61.2% recall, 65.7% for mAP, and 71.5% for the model. Overall, the neural network designed in the algorithm proved to be a potential tool for defect classification and localization

Keywords: Wire Arc Additive Manufacturing, Machine Learning, Neural Network, YOLO, IN-SITU Monitoring, Classification and Recognition

LISTA DE FIGURAS

FIGURA 1: TIPOS DE SOLDAGEM A ARCO ELÉTRICO (LI; SU; ZHU, 2022)	25
FIGURA 2: REPRESENTAÇÃO DO PROCESSO DE MADA (AUTORIA PRÓPRIA).....	26
FIGURA 3: POROSIDADE SUPERFICIAL (AUTORIA PRÓPRIA).....	28
FIGURA 4: DEFEITO DE HUMPING (AUTORIA PRÓPRIA).....	29
FIGURA 5: INCLUSÕES DE ESCÓRIA. (AUTORIA PRÓPRIA).	29
FIGURA 6: DELAMINAÇÃO E TRINCA DE CAMADA (SAMES ET AL., 2016)	30
FIGURA 7: DEFEITO DE DISTORÇÃO NO SUBSTRATO. A: ANTES DO APARECIMENTO, B: DEPOIS DO APARECIMENTO, C: EXEMPLO REAL OBTIDO EM LABORATÓRIO (AUTORIA PRÓPRIA). 31	
FIGURA 8: (A) DIVISÃO GERAL DA IA, (B) REPRESENTAÇÃO DE UMA REDE NEURAL BÁSICA (AUTORIA PRÓPRIA).....	34
FIGURA 9: EXEMPLO DE DETECÇÃO DE OBJETOS EM IMAGENS (FELZENSZWALB ET AL., 2010).....	36
FIGURA 10: PROCESSO GERAL DE DETECÇÃO DO YOLO (REDMON ET AL., 2016). ADAPTADO	37
FIGURA 11: CONFIGURAÇÃO EXPERIMENTAL DO ROBÔ MADA (AUTORIA PRÓPRIA)	42
FIGURA 12: TELA PRINCIPAL DO MACH3 (AUTORIA PRÓPRIA).....	43
FIGURA 13: ESTRATÉGIA DE DEPOSIÇÃO ZIG-ZAG (AUTORIA PRÓPRIA)	43
FIGURA 14: TÉCNICA DE FLIPPING (AUTORIA PRÓPRIA).....	45
FIGURA 15:TÉCNICA DE ROTAÇÃO (AUTORIA PRÓPRIA)	46
FIGURA 16: APLICAÇÃO DE FILTRO GAUSSIANO (AUTORIA PRÓPRIA).....	46
FIGURA 17: TÉCNICA CROPPING (AUTORIA PRÓPRIA)	47
FIGURA 18: INTERFACE DO CVAT (AUTORIA PRÓPRIA)	48
FIGURA 19: FLUXOGRAMA DO PROCESSO DE CRIAÇÃO DO BANCO DADOS (AUTORIA PRÓPRIA)	51
FIGURA 20: PROCESSO DE APLICAÇÃO DA REDE NEURAL UTILIZADA (AUTORIA PRÓPRIA)	51
FIGURA 21: INTERFACE DE INTERAÇÃO PARA DETECÇÃO DE DEFEITOS OFFLINE (AUTORIA PRÓPRIA)	53
FIGURA 22: INTERFACE DE INTERAÇÃO PARA DETECÇÃO DE DEFEITOS IN-SITU (AUTORIA PRÓPRIA)	54
FIGURA 23: VISTA FRONTAL DA PAREDE (AUTORIA PRÓPRIA)	57
FIGURA 24: EFEITO DA TRANSIÇÃO DO HUMPING DA PAREDE (AUTORIA PRÓPRIA)	58
FIGURA 25: DEFEITO DE POROSIDADE DA PAREDE (AUTORIA PRÓPRIA)	59
FIGURA 26: DEFEITO DE INCLUSÃO DE ESCÓRIA DA PAREDE 9 (AUTORIA PRÓPRIA).....	59
FIGURA 27: CURVA DA FUNÇÃO DE PERDA DO TREINAMENTO POR ÉPOCAS (AUTORIA PRÓPRIA).....	61
FIGURA 28: CURVA DA FUNÇÃO DE PERDA DA VALIDAÇÃO POR ÉPOCAS (AUTORIA PRÓPRIA)62	
FIGURA 29: MATRIZ DE CONFUSÃO PARA B1 (AUTORIA PRÓPRIA)	63
FIGURA 30: MATRIZ DE CONFUSÃO PARA B2 (AUTORIA PRÓPRIA).....	63
FIGURA 31: MATRIZ DE CONFUSÃO PARA B3 (AUTORIA PRÓPRIA)	64
FIGURA 32: COMPARAÇÃO DAS PRECISÕES DOS MODELOS (AUTORIA PRÓPRIA)	65
FIGURA 33: COMPARAÇÃO DOS RECALLS DOS MODELOS (AUTORIA PRÓPRIA).....	66
FIGURA 34: COMPARAÇÃO DOS MAPs DOS MODELOS (AUTORIA PRÓPRIA)	66
FIGURA 35: MÉTRICA F1 PARA B1 (A), B2 (B) E B3 (C).....	67

LISTA DE TABELAS

TABELA 1: COMPOSIÇÃO QUÍMICA DO ARAME E SUBSTRATO (AUTORIA PRÓPRIA)	41
TABELA 2: DIVISÃO DAS INCLUSÕES DE DEFEITOS NAS PAREDES FABRICADAS (AUTORIA PRÓPRIA)	44
TABELA 3: PARÂMETROS FIXOS UTILIZADOS NOS EXPERIMENTOS (AUTORIA PRÓPRIA)	44
TABELA 4: QUANTIDADE DE IMAGENS PARA CADA BANCO DE DADOS	49
TABELA 5: MATRIZ DE CONFUSÃO.....	55
TABELA 6: MÉTRICAS PARA O BANCO DE DADOS B1 COM E SEM TUNING.....	60
TABELA 7: MÉTRICAS PARA O BANCO DE DADOS B2 COM E SEM TUNING.....	60
TABELA 8: MÉTRICAS PARA O BANCO DE DADOS B3 COM E SEM TUNING.....	61
TABELA 9: MÉTRICAS PARA OS MELHORES PESOS DE CADA MODELO	68

LISTA DE SIGLAS E ABREVIATURAS

AP - Average Precision
CNN - Convolutional Neural Network
CSCCN - Cost-Sensitive Convolutional Neural Network
CVAT - Computer Vision Annotation Tool
DL - Deep Learning
FN - Falso Negativo
FP - Falso Positivo
IA - Inteligência Artificial
IHM - Interface Homem Máquina
MA - Manufatura Aditiva
MAAL - Manufatura Aditiva Auxiliada por Laser
MADA - Manufatura Aditiva por Deposição ao Arco
mAP - Mean Average Precision
ML - Machine Learning
VC - Visão Computacional
VN - Verdadeiro Negativo
VP - Verdadeiro Positivo
FP – Falso Positivo
FN – Falso Negativo
YOLO - You Only Look Once

SUMÁRIO

1. INTRODUÇÃO.....	20
1.1. Objetivo Geral	21
1.2. Objetivos Específicos.....	21
2. JUSTIFICATIVA.....	22
3. REVISÃO BIBLIOGRÁFICA.....	22
3.1. Manufatura Aditiva	22
3.2. Manufatura Aditiva por Deposição a Arco (MADA)	24
3.3. Alguns defeitos comuns em componentes fabricados por MADA.....	27
3.3.1. Porosidade.....	27
3.3.2. Humping	28
3.3.3. Respingos.....	29
3.3.4. Fissura e delaminação	30
3.3.5. Tensão residual e distorções	30
3.4. Temperatura interpasse	31
3.5. Aços inoxidáveis	31
3.5.1. O aço Inoxidável Austenítico 316L-Si	32
3.6. Inteligência Artificial.....	32
3.6.1. Redes Neurais Convolucionais (CNN).....	34
3.6.2. Detecção de objetos	35
3.6.3. You Only Look Once (YOLO).....	36
3.7. Trabalhos relacionados a detecção de defeitos superficiais em MADA através de CNNs	38
4. MATERIAIS E MÉTODOS.....	40
4.1. Caracterização da pesquisa.....	40
4.2. Dependências e Hardware utilizados no treinamento	40
4.3. Materiais	40
4.4. Manipuladores Robóticos.....	41
4.4.1. Software Mach3 para controle da CNC	42
4.5. Estratégia de deposição.....	43
4.6. Coleta de dados	43
4.7. Técnicas de aumento de dados artificialmente	45
4.7.1. Flipping	45
4.7.2. Rotação	46

4.7.3.	Aplicação de filtro Gaussiano.....	46
4.7.4.	Aplicação de filtro de contraste e alteração de brilho.....	47
4.7.5.	Cropping	47
4.8.	Computer Vision Annotation Tool (CVAT).....	48
4.9.	Concepção dos bancos de dados	48
4.10.	Detecção baseada no algoritmo para treinamento do YOLO	49
4.11.	Interface Homem Máquina (IHM)	52
4.11.1.	Detecção Off-line	53
4.11.2.	Detecção In-situ	53
4.11.3.	Aba de ajuda.....	54
4.12.	Métricas de Avaliação.....	54
5.	Resultados e Discursões.....	57
5.1.	Inspeção Visual.....	57
5.1.1.	Inspeção Visual (Humping).....	58
5.1.2.	Inspeção Visual (Porosidade)	58
5.1.3.	Inspeção Visual (Inclusão de escória)	59
5.2.	Desempenho dos modelos treinados.....	59
5.2.1.	Comparação dos modelos no banco de dados de teste	62
6.	CONCLUSÕES.....	69
7.	TRABALHOS FUTUROS.....	70
8.	REFERÊNCIAS.....	71

1. INTRODUÇÃO

A Manufatura Aditiva (MA) é um processo de fabricação de objetos tridimensionais que consiste na deposição de materiais camada por camada, diretamente a partir de um modelo de geometria computacional. Essa tecnologia tem o potencial de eliminar em grande medida as restrições de design e fabricação impostas pelos métodos convencionais de fabricação (SUN et al., 2021). Sua grande flexibilidade somado a uma rapidez de produção e economia de material são características que fazem a MA, também conhecida como impressão 3D, ganhar destaque quando se fala em demanda por produtos de maior qualidade e durabilidade atrelados à redução de consumo e preservação do meio ambiente. Outra importante vantagem diz respeito ao potencial de redução de tempo da colocação de produtos no mercado devido a fatores como: redução de montagem, instalações e ferramentas da máquina (TOWNSEND et al., 2016), assim como a eliminação de moldes (ZHANG et al., 2018).

Dentre os processos de MA existentes, a norma (ISO, 2015) os classifica em: *Binder Jetting* (BJ), *Powder-Bed Fusion* (PBF), *Sheet Lamination* (SL) e *Direct Energy Deposition* (DED), *Vat Photopolymerization* (VPP), *material extrusion* (ME), e *material jetting*. Assim, para a MA de metais, as tecnologias mais usadas são PBF e DED (ZHANG et al., 2018). A MA pode ser utilizada em diversos setores industriais como naval, aeroespacial, odontológica, automobilística, bens de consumo em geral, automobilístico, construção ou reparos de moldes, matrizes e componentes para injeção de plásticos (FERRARESI, 2018).

A Manufatura Aditiva por Deposição a Arco (MADA), um dos tipos de DED, é um processo baseado a arco elétrico formado entre o arame e o substrato ou as camadas subsequentes (ZHANG et al., 2018). Tal método oferece vantagem de aplicação em larga escala para fabricação de peças maiores e retenção de melhores superfícies (KOZAMERNIK; BRAČUN; KLOBČAR, 2020). E, quando comparados à usinagem, normalmente é possível reduzir os tempos de produção de 40% a 60% (WILLIAMS; MARTINA, 2015).

Graças a grande complexidade da MADA, como propriedades de materiais, monitoramento e layout, existe a necessidade de estudo de uma extensa quantidade de tópicos como propriedades dos materiais, qualidade de superfície e, somado a isso, características e defeitos inerentes ao sistema, que são necessários para uma

melhor compreensão do processo. Apesar do desenvolvimento, a MADA enfrenta críticas à estabilidade do processo como raio de aquecimento, grande intensidade de calor, tensões residuais, porosidade, trincas, escoria entre outros problemas (WU et al., 2023). O processo possui diversas variáveis que influenciam o desempenho como velocidade de soldagem, ângulo e inclinação da tocha, velocidade de alimentação do arame entre outros.

Para alcançar alto desempenho de todo o processo, a indústria atualmente requer uma colaboração mais próxima entre a fabricação, detecção de defeitos, e qualidade do produto final. Assim, sistemas que melhorem o processo de detecção de defeitos são necessários. Nesse cenário, tecnologias de *Machine Learning* (ML), graças aos avanços em Inteligência Artificial (IA), têm sido bastante usadas para melhoramento de designers e aprimoramento da qualidade em MADA (HAMRANI et al., 2023) através da extração de informações ocultas e estabelecimento de vínculos extremamente complexos (LASI et al., 2014).

1.1. *Objetivo Geral*

Implementar um sistema de monitoramento e identificação de descontinuidades superficiais *in situ* e offline em pré-formas metálicas obtidas pelo processo de Manufatura Aditiva por Deposição a Arco (MADA), através da aplicação do empregando do modelo YOLO em sua versão 8.

1.2. *Objetivos Específicos*

- Desenvolver um protótipo de sistema para o monitoramento de defeitos superficiais;
- Aplicar aprendizado de máquina a imagens, retiradas durante a fabricação, para obter informações que possam relacionar e classificar defeitos;
- Criação de um banco de dados de defeitos superficiais em MADA para uso acadêmico;
- Criação e aplicação do algoritmo baseado em uma Rede Neural Convolutacional, utilizando mais especificamente o YOLOv8, para detecção e classificação de defeitos superficiais através de reconhecimento de imagem em pré-formas fabricadas por MADA;
- Criação de uma IHM para controlar e visualizar os defeitos em tela.

2. JUSTIFICATIVA

A indústria busca todos os dias melhorar a qualidade, economicidade e confiabilidade em seus produtos. Nesse cenário, a MADA surge como alternativa para obtenção de peças para os diferentes setores industriais, como nas indústrias aeroespacial, militar, de moldes e matrizes, energia nuclear e naval, isso também inclui fabricação de hélices para aplicações navais, trens de pouso para indústria aeronáutica, nervuras de asas e caixas de motor e braços de escavadeira (JAFARI; VANEKER; GIBSON, 2021). Além disso, também encontra mercado em aplicações de produtos alimentícios, na área da saúde com a produção de implantes médicos e dentários e na indústria automobilística na fabricação de pistões e discos de freio (MILEWSKI; MILEWSKI, 2017). Contudo, a formação de defeitos em componentes fabricados por MADA ainda é um desafio para aplicabilidade e estrutura. Caso as falhas não sejam corrigidas, elas poderão afetar de forma negativa o desempenho de um componente durante sua aplicação final. Assim, é importante ter um conhecimento sobre os mecanismos de geração de defeitos (ZAHIDIN et al., 2023).

Desse modo, estudos e trabalhos com o objetivo de adaptação aos requisitos de detecção de defeitos em MADA são de grande importância, pois possibilitam a aplicação desse sistema com uma maior segurança, economicidade, tempo e segurança nos setores das indústrias. A utilização de um sistema de detecção de defeitos *in situ* é de grande importância tanto para a aplicação da técnica prática, como na aplicação dos conhecimentos teóricos na área da soldagem. Dessa forma, esta pesquisa desempenha um importante papel na geração e refinamento de conhecimentos, além do aprimoramento do domínio técnico de um processo que tem evoluído continuamente nas indústrias.

3. REVISÃO BIBLIOGRÁFICA

3.1. Manufatura Aditiva

A manufatura Aditiva (MA) é uma tecnologia de produção de peças em 3D na qual camadas são depositadas umas sobre as outras a partir de dados de um modelo tridimensional computacional. Em oposição à fabricação subtrativa, na qual há retirada de material, a MA acontece a adição de material, depositando camada sobre camada

até se chegar à forma final, permitindo, assim, uma maior liberdade de projeto, redução de desperdício, montagem complexa de peças, rapidez de produção e preservação do meio ambiente (DEBROY et al., 2018; DEMIR, 2018) além de poder ser aplicada no reparo de peças (CHEN et al., 2018). Graças às suas vantagens de flexibilidade e poder usar diferentes tipos de materiais, como metais, concreto e polímeros, a impressão 3D é um importante tema de pesquisa apesar de mais de 45 anos depois de seu início, tendo recebido bastante atenção de campos como aeroespacial, elétrica, biomedicina e de projetos arquitetônicos (LIU et al., 2020). Tida com o potencial de alterar as estratégias de produção e os processos produtivos empregados a MA, conforme (HUANG et al., 2013), é a tecnologia do futuro, por ser altamente provável que a MA traga impactos significativos em um futuro próximo.

Desde seu primeiro uso em 1986, com estereolitografia (SL) da *3D Systems*, a MA deu origem a muitos outros tipos de técnicas e, nos últimos anos, a participação da MA no mercado foi relatada em 21%, no qual processos de Adição de Metal contribuíram com cerca de 80% de todos os processos de MA usados comercialmente (MADHAVADAS et al., 2022). De acordo com a norma da *American Society for Testing and Materials*, dentre os tipos existentes para fabricação com componentes metálicos são destacadas as seguintes:

- *Binder Jetting* (BJ): Se utiliza de pó metálico com um aglutinante, que consolida o pó dentro e entre as camadas, para imprimir as peças desejadas. Assim, terminada a impressão, a peça pode ser usada tal como está curada, infiltrada ou sinterizada (WHEAT et al., 2018).
- *Powder-Bed Fusion* (PBF): é uma categoria de processo de MA na qual a energia térmica funde seletivamente regiões de um leito de pó e, depois de cada camada, uma placa de impressão é abaixada e um rolo adiciona uma nova camada de material em pó (VAFADAR et al., 2021).
- *Sheet Lamination* (SL): O material é depositado em forma de folhas de material camada por camada para construir o componente desejado. Cada folha é cortada por uma ferramenta, como um laser, no formato certo para se ajustar a secção transversal (VAFADAR et al., 2021).
- *Direct Energy Deposition* (DED): Possuem uma fonte de energia concentrada que derrete uma matéria-prima dando origem a poça de fusão e construindo

suas deposições. Existem vários sistemas de *DED*, os quais incluem: sistemas baseados em fusão e baseados em energia cinética. Sistemas *DED* de fusão podem ser subclassificados em: baseado em feixe de elétrons, baseado em plasma, baseado em arco elétrico (MADA) e baseado em laser (DASS; MORIDI, 2019).

- *Vat Photopolymerization (VPP)*: Através de uma fonte de luz (UV) o material vindo de um reservatório é curado e transformado em camadas solidificadas. Das tecnologias existentes nessa categoria as StereoLithography (SLA) e Digital Light Processing (DLP) são usadas para imprimir peças parcialmente metálicas (VAFADAR et al., 2021).
- *Material extrusion (ME)*: Um filamento sólido é transportado através de um bocal de extrusão aquecido em um caminho pré-definido para uma mesa de construção aquecida, resultando em uma fabricação camada por camada da peça 3D (SPOERK; HOLZER; GONZALEZ-GUTIERREZ, 2020).
- *Material jetting (MJ)*: Uma resina é pulverizada seletivamente no local, através de um mecanismo térmico ou piezoelétrico, e, logo após, uma fonte de luz é usada para curar e solidificar o material. Essa tecnologia permite a impressão 3D multicolorida e de multimateriais (MANAIA; CEREJO; DUARTE, 2023).

3.2. *Manufatura Aditiva por Deposição a Arco (MADA)*

No método DED, a alimentação, de arame ou pó, é colocada diretamente na poça de fusão por uma fonte de aquecimento, fazendo com que o material funda e se deposite camada sobre camada em um substrato (DEBROY et al., 2018) e tendo como características a habilidade de construção de peças grandes, possibilidade de usar taxas de deposição relativamente altas e uma boa eficiência energética (SILVA, 2020). Nesse sentido, para MA de metais, as mais usadas são PBF e DED (THOMAS-SEALE et al., 2018).

Entre as variantes do DED, a MADA é um processo baseado nos princípios da soldagem por arco elétrico, podendo ser dividida, conforme a forma como o arco é produzido, em: Gas Tungsten Arc Welding (GTAW), Gas Metal Arc Welding (GMAW) e Plasma Arc Welding (PAW), Figura 1.

O processo GTAW, ou soldagem TIG (*Tungsten Inert Gas*), pode produzir soldas de alta qualidade através de um arco aberto entre um eletrodo de tungstênio não consumível e a peça de trabalho enquanto a alimentação do material de adição é feita separadamente. Nesse processo não há escória ou respingos e requer pouca limpeza pós-soldagem e tem sido bastante utilizado nas indústrias aeroespacial, aeronáutica e de geração de energia por exemplo. O PAW consiste em um o arco que é comprimido através de um bico tendo, assim, como resultado mais constrição e melhoria da estabilidade do arco, aumento da eficiência e das velocidades de soldagem (LI; SU; ZHU, 2022). Já no processo GMAW, também chamado de MIG (*Metal Inert Gas*), o arco é formado diretamente no arame de adição, o qual é considerado consumível, e o substrato ou as camadas subsequentes (ZHANG et al., 2018). Incorpora um sistema de alimentação automática que pode ser perpendicular ao substrato, possui uma alta eficiência de fusão e deposição, sendo apropriado para soldagem de metais comercialmente importantes, como o aço inoxidável e o alumínio (LI; SU; ZHU, 2022). Nesse trabalho o processo utilizado foi o GMAW.

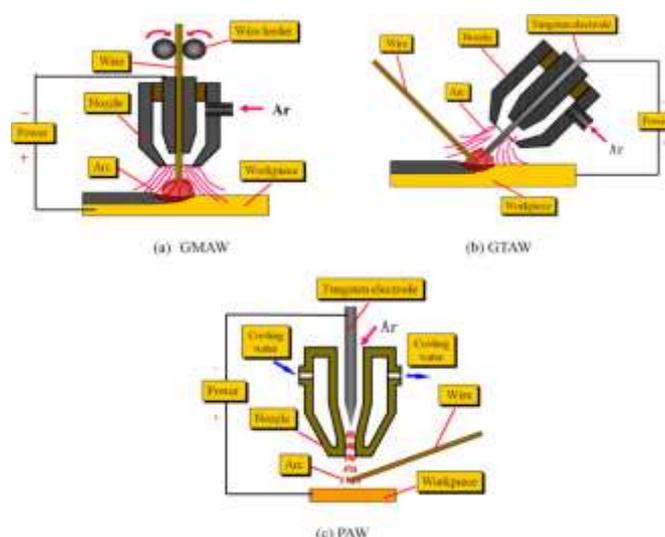


Figura 1: Tipos de soldagem a arco elétrico (LI; SU; ZHU, 2022)

A Figura 2 apresenta um sistema típico de MADA, com unidade de controle computacional, máquina de solda a arco, alimentador de arame, um robô ou sistema de Controle Numérico Computadorizado (CNC), tocha de soldagem e um substrato.

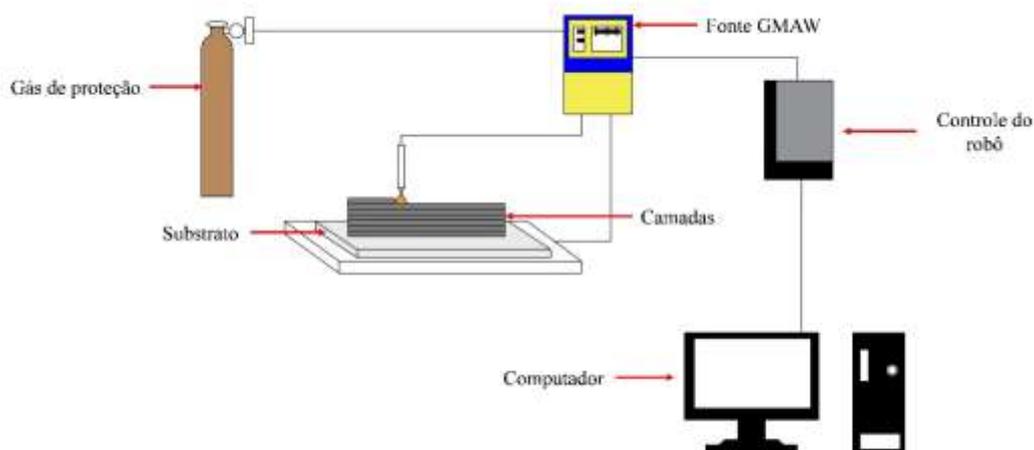


Figura 2: Representação do processo de MADA (Autoria própria)

A MADA ao empregar arames sólidos como material de adição possui uma eficiência que pode chegar aos 100 % se comparada ao processo que emprega pó como material de adição, a MADA é, portanto, um processo mais ecológico além de não expor os operadores a ambientes perigosos como os que trabalham com alimentação de pós. Somado a isso, quando comparado a alimentação de pó, o processo alimentado por arame apresenta uma taxa de deposição significativamente maior, chegando até 2500 cm/h^3 (330 g/min para aço inoxidável (DING et al., 2015). Já quando comparado aos métodos de fabricação subtrativa tradicionais normalmente é possível reduzir os tempos de produção de 40% a 60% e os tempos de pós-usinagem entre 15% e 20% a depender do tamanho e geometria (WU et al., 2018a). Além disso, oferece uma redução do valor por quilo quando comparado ao emprego de pós (CUNNINGHAM et al., 2018).

Embora o GMAW também apresente a vantagem de sua taxa de deposição ser de duas a três vezes maior do que o GTAW ou PAW, este processo apresenta uma menor estabilidade e gera mais defeitos superficiais como respingos e geometria defeituosa, devido à corrente elétrica que atua diretamente no metal de adição. Desse modo, a escolha do tipo de processo conexo a MADA tem influência direta nas condições de processamento e taxa de produção para construção de um componente (WU et al., 2018b). Assim, mesmo que, em relação as propriedades mecânicas, os componentes fabricados por MADA sejam comparáveis às dos fabricados convencionalmente, existem defeitos que devem ser investigados para aplicações críticas, bem como devem ser desenvolvidos critérios de aceitação após inspeção.

Tais defeitos podem acontecer por vários motivos, entre eles estratégia de programação inadequada, dinâmica instável da poça, configuração inadequada dos parâmetros e/ou deformação térmica associada ao acúmulo de calor (WU et al., 2018a).

3.3. Alguns defeitos comuns em componentes fabricados por MADA

Os defeitos em componentes MADA são um grande desafio para sua aplicação, pois, caso as falhas não sejam corrigidas, podem afetar de forma negativa o processo e causar falhas catastróficas do componente durante o uso. Desse modo, é de extrema importância o conhecimento dos mecanismos de formação dos mesmos a fim de poder estabelecer os parâmetros de processo mais ideais, levando em consideração tanto o sistema de liga quanto a técnica de processamento utilizada (ZAHIDIN et al., 2023).

A alta energia térmica do arco induz alta tensão residual, devido aos rápidos e repetidos caminhos de aquecimento, o que influencia a rugosidade superficial (irregularidades ou regulares em uma superfície) diminuindo a qualidade e o desempenho mecânico das camadas sobrepostas sendo necessário pós-processamento de usinagem (NOMOTO et al., 2022). Os parâmetros do processo, como temperatura intercamada (IT), vazão do gás de proteção (GV), velocidade de alimentação do arame (WFS) e velocidade de deslocamento (TS), estão profundamente ligados ocorrência desses defeitos e conseqüentemente sobre a qualidade final do produto (SO et al., 2022).

3.3.1. Porosidade

A porosidade, Figura 3, é um defeito comum que surge nos processos MADA e afeta de forma negativa nas propriedades mecânicas devido a danos causados pela formação de microfissuras e, muitas vezes, faz com que a camada depositada tenha as propriedades de fadiga inferiores devido à distribuição espacial de padrões variados de forma e tamanho (ZAHIDIN et al., 2023). Em geral, tal defeito é causado principalmente por baixa pureza do gás, parâmetros errados, impureza do material do arame ou substrato, fluxo insuficiente do gás ou alta velocidade de soldagem (BUSACHI et al., 2015) além da presença de contaminantes na superfície como

umidade e graxa. Normalmente, os poros ficam presos na camada superior da zona de fusão. Assim, ao passo que finas películas de óxido se formam na superfície da poça, elas absorvem o hidrogênio molecular e umidade do ar, contribuindo para um aumento na quantidade de hidrogênio presente na camada superior. Como consequência, é comum encontrar uma maior retenção de hidrogênio e pequenos microporos na zona da linha de fusão de cada camada. Além disso, uma maior entrada de calor também leva a uma maior incidência de porosidade (ZAHIDIN et al., 2023).

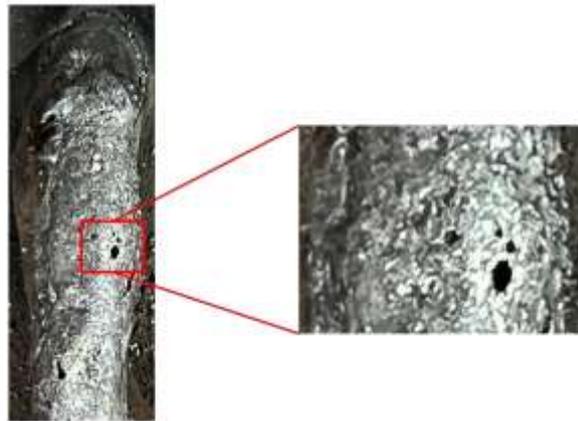


Figura 3: Porosidade Superficial (Autoria própria)

3.3.2. *Humping*

O defeito de *humping* ou protuberância pode ser descrito como a formação de protuberâncias em um cordão de solda em intervalos regulares. Também pode ser descrito como uma ondulação periódica do cordão de solda, se constituindo de um vale e uma ondulação (ADEBAYO; MEHNEN; TONNELIER, 2012) Figura 4. O defeito de *humping* é típico da soldagem convencional por fusão, quando se usam normalmente altas velocidades de deslocamento e pouco controle do comprimento do arco elétrico, seja devido a problemas no sistema de alimentação do arame ou falta de controle da DBCP (distância do bico de contato a peça). Sua ocorrência limita o aumento da velocidade de soldagem e, portanto, a melhoria da eficiência (WU et al., 2017).

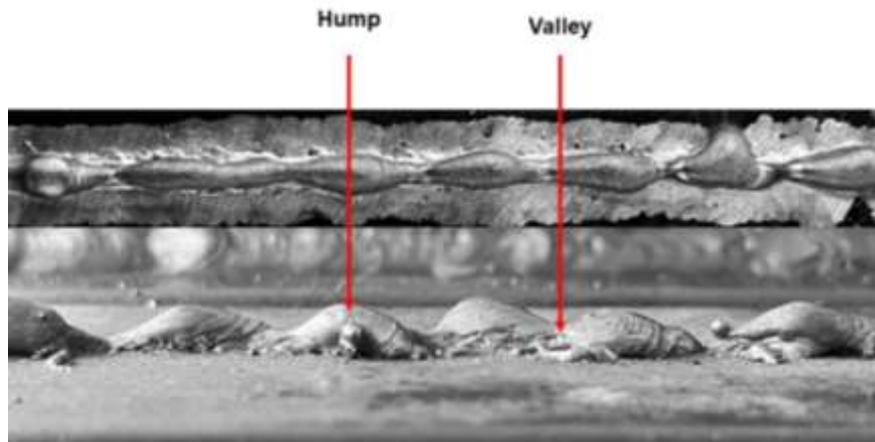


Figura 4: Defeito de Humping (Autoria própria)

3.3.3. Respingos

Durante a fabricação de componentes por MADA, reações químicas ocorrem na poça de fusão a uma alta temperatura, o que produz uma grande quantidade de óxidos, silicatos, nitretos e outros compostos, Figura 5. A maior parte escapa da poça de fusão, porém uma parcela permanece nas camadas e formam respingos que afetam a qualidade superficial da peça fabricada. Além disso, segundo (MENESES, 2013) *apud* (SOUZA et al., 2011), o comprimento do arco tem influência sobre a estabilidade da transferência metálica que afeta a formação de respingos. Ainda conforme os autores, outro efeito que afeta a formação de respingos é uma pressão da extremidade fundida do eletrodo na poça, devido ao avanço constante do arame no curto-circuito.



Figura 5: Inclusões de escória. (Autoria própria).

3.3.4. Fissura e delaminação

A formação dos defeitos depende essencialmente da temperatura do processo. Assim, a rachadura, ou fissuração, pode ocorrer na microestrutura durante o aquecimento ou solidificação subsequente e, as fissuras macroscópicas, também podem estar relacionadas com outros defeitos como a porosidade e também depende do material e pode haver alguns casos de processamento em que a fissuração é inevitável (SAMES et al., 2016). A delaminação leva a fissuração entre camadas está apresentada na Figura 6. A separação de camadas ou delaminação ocorre graças à fusão incompleta ou à refusão insuficiente dos sólidos subjacentes entre camadas. Normalmente, é bastante visível e não pode ser reparada sendo que, para evitar seu aparecimento, tem que se considerar um tratamento prévio, como pré-aquecimento do substrato, fios mistos, e diminuição da taxa de resfriamento (WU et al., 2018a).

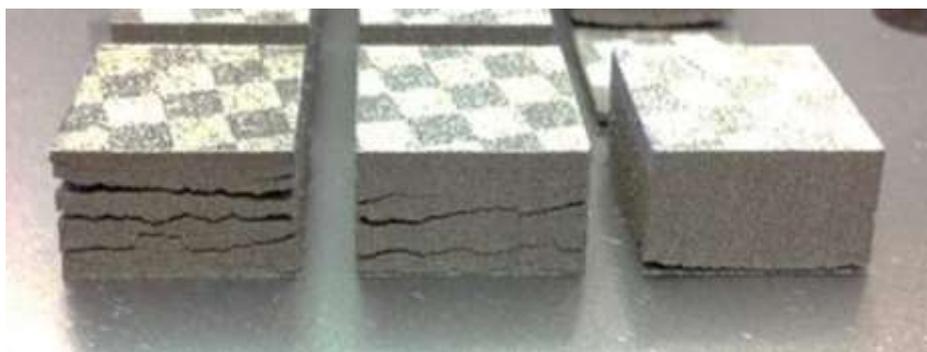


Figura 6: Delaminação e trinca de camada (SAMES et al., 2016)

3.3.5. Tensão residual e distorções

Assim como em vários processos de MA, as peças fabricadas por MADA possuem distorções e tensões residuais intrínsecas ao seu mecanismo de fabricação causadas pela alta temperatura (DING et al., 2011). Os substratos utilizados para deposições das camadas podem sofrer deformações devido à temperatura operacional do processo, ao tratamento térmico do substrato antes do uso ou devido a coeficientes diferenciais de expansão térmica (SAMES et al., 2016) conforme Figura 7. Desse modo, os componentes fabricados por MADA podem exibir vários tipos de deformações, entre elas distorção rotacional, distorção angular, distorção de flexão e encolhimento longitudinal e transversal (ZAHIDIN et al., 2023). A distorção leva a tolerâncias de construção baixas, enquanto a tensão residual afeta de forma negativa

o desempenho da peça construída (COLEGROVE et al., 2013) A seguir, na Figura 7, é apresentado o a formação do defeito de distorção e um exemplo real obtido em laboratório.

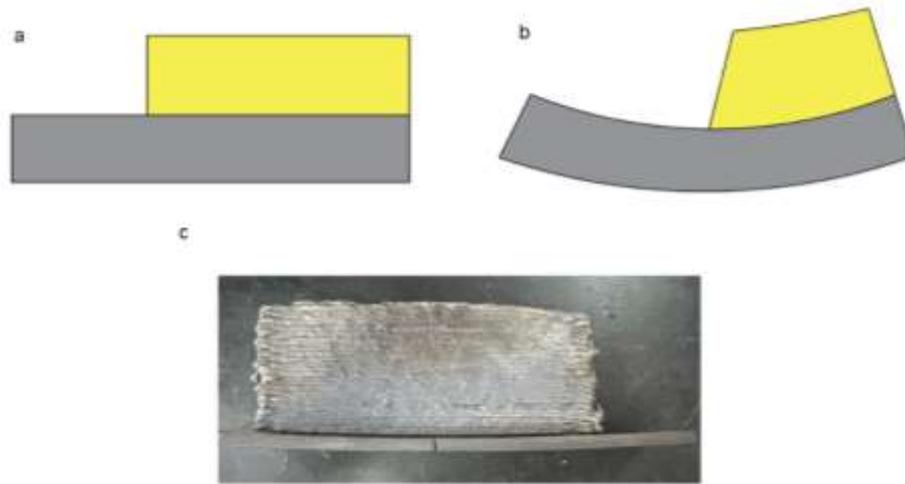


Figura 7: Defeito de Distorção no substrato. a: antes do aparecimento, b: depois do aparecimento, c: exemplo real obtido em laboratório (Autoria própria).

3.4. Temperatura interpasse

O acúmulo de calor no processo é um aspecto importante, pois o aumento da temperatura interpasse (IT) pode causar retardo no resfriamento e solidificação da peça, resultando em uma largura maior e altura reduzida (KOZAMERNIK; BRAČUN; KLOBČAR, 2020). A temperatura de interpasse é, para norma (A. ISO, 2017) 113916, a temperatura máxima de uma solda multipasse e do metal imediatamente antes da passagem subsequente. Seu controle garante a repetibilidade do sistema além de garantir uma maior homogeneidade das propriedades do sistema podendo influenciar na formação de defeitos ou não conformidades na microestrutura e geometria (TEIXEIRA et al., 2023). Tal controle, dentro de uma faixa razoável, é de extrema importância para manipulação das microestruturas, propriedades mecânicas e eficiência do processo.

3.5. Aços inoxidáveis

Os aços inoxidáveis representam uma classe crucial de ligas, o que evidencia a sua importância por meio de uma grande gama de aplicações. Desde o uso de utensílios de cozinha e móveis, até aplicações altamente sofisticadas, como veículos espaciais. De fato, a onipresença dessas ligas em nosso cotidiano torna praticamente

impossível enumerar todas as suas aplicações (LO; SHEK; LAI, 2009). Com no mínimo 11 % de cromo (Cr), as ligas de cromo e ferro (Fe) recebem essa denominação e possuem uma capacidade de gerar uma camada fina de óxido na superfície, o que faz com esse material tenha elevada resistência a corrosão atmosférica (SOUZA, 2022). Outros elementos químicos podem ser adicionados a liga com intuito de melhorar as propriedades do material como Mo, para aumentar a resistência contra pites e Ni, para obtenção da austenita.

Os Aços inoxidáveis podem ser divididos, conforme (BOTTON, 2008; SOUZA, 2022) em: Martensíticos, com 12%-17%Cr e 0,1%-1,0%C; Ferríticos com 10,5%-30%Cr e 0,12%C; Austeníticos, com 17%-25%Cr e 8%-20%Ni e duplex com 18%-28%Cr, 4,5%-8%Ni e adições de Mo na faixa de 2,5%-4%Mo podendo possuir variações de N variando entre 0,16%-0,18%N.

3.5.1. O aço Inoxidável Austenítico 316L-Si

Os aços inoxidáveis austeníticos são ligas versáteis com vários tipos de aplicações graças a sua excelente resistência a corrosão, equilibradas propriedades mecânicas em altas e baixa temperaturas, boa processabilidade e alta tenacidade, tendo, entre as ligas mais usadas, a liga 316L e o 316L-Si (PALMEIRA BELOTTI et al., 2022). São preferíveis nas indústrias de energia, construção naval, nuclear, química e aplicações criogênicas. Possui uma estrutura interna austenítica diferente dos outros aços inoxidáveis. Além disso, possui uma resistência intergranular a corrosão elevada, graças ao baixo teor de carbono que não deteriora o cromo para formar carbonetos de cromo, e suas propriedades de tenacidade são significativamente boas e nenhuma transformação martensita é observada durante o resfriamento (TÜMER; YILMAZ, 2016).

3.6. Inteligência Artificial

O termo Inteligência Artificial, em sua definição mais estrita, é descrito como a imitação por computadores da inteligência inerente aos humanos (SHEIKH; PRINS; SCHRIJVERS, 2023). Em Ciência da Computação, IA é o estudo de qualquer dispositivo que consiga perceber seu ambiente e tome decisões que aumentem a probabilidade de atingir seus objetivos (SHINDE; SHAH, 2018). Assim, embora os

termos Inteligência Artificial (IA), *Machine Learning (ML)* e *Deep Learning (DL)* tenham conexões entre si, eles não são os mesmos (ZHANG et al., 2022), conforme pode ser visto na Figura 8 (a), na qual é mostrada uma Divisão geral da IA.

Desse modo, Aprendizagem de Máquina, do Inglês: *Machine Learning (ML)*, é um subconjunto da (IA) que trata do estudo científico de modelos estatísticos e algoritmos para execução de tarefas específicas que os sistemas computacionais executam. Baseado na concepção que tais sistemas podem aprender com dados e identificar padrões para tomar decisões os algoritmos de ML possuem variadas aplicações, como reconhecimento de voz, visão computacional e processamento de linguagem natural (ARAÚJO, 2022; JANIESCH; ZSCHECH; HEINRICH, 2021). Assim, os avanços em ML possibilitaram o desenvolvimento recente de sistemas inteligentes com habilidades cognitivas comparáveis às humanas, que estão cada vez mais presentes em nossos negócios e vidas pessoais (JANIESCH; ZSCHECH; HEINRICH, 2021).

ANN têm sua origem a partir da inspiração pelo sistema nervoso humano sendo um modelo capaz de representar funções não lineares (BLOCK, 2018). São um sistema de modelagem de dados não lineares no qual modelos ou padrões são estabelecidos em relacionamentos complexos entre entradas e saídas (QAMAR; ZARDARI, 2023). Ou seja, elas têm o objetivo de simplificar uma realidade complexa de forma que se deduz uma função para representar as observações estatísticas que esperadas da realidade (FERRANTE, 2023). A Figura 8 (b) apresenta a representação de uma ANN básica, no qual é possível observar as camadas de entrada, que são responsáveis pela distribuição das informações para a(s) camada(s) escondida(s) da rede. Já a segunda camada é responsável pelos cálculos intermediários para identificar padrões e características nos dados, através da atribuição de pesos e a terceira camada fornece o resultado final do processamento, como por exemplo uma classificação ou previsão.

Nesse contexto, o aprendizado profundo do Inglês: *Deep Learning (DL)*, um subconjunto de ML que usa Redes Neurais Artificiais, do inglês *Artificial Neural Network (ANN)* (TESHALE et al., 2024), é uma rede neural com um grande número de parâmetros e múltiplas unidades de processamento em camadas para extração e transformação de recursos (SHINDE; SHAH, 2018). O DL está fazendo grandes avanços e se mostrando melhor que o ML convencional para a maioria das aplicações

de processamento de dados de texto, imagem, vídeo, fala e áudio (LECUN; BENGIO; HINTON, 2015).

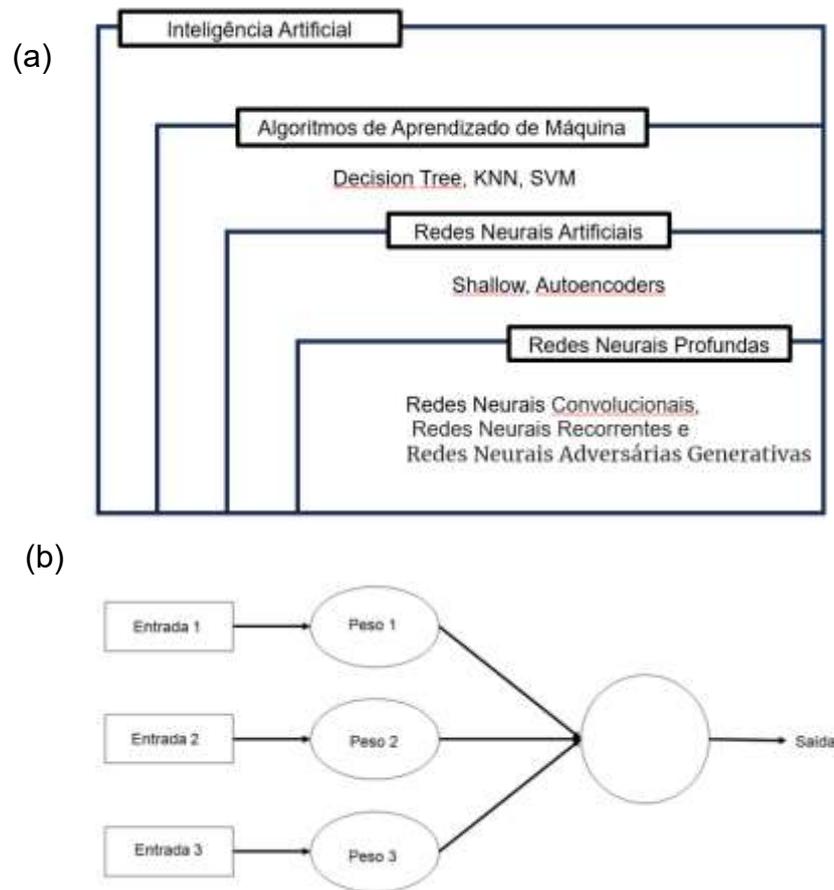


Figura 8: (a) Divisão geral da IA, (b) Representação de uma Rede Neural básica (autoria própria)

3.6.1. Redes Neurais Convolucionais (CNN)

Uma CNN é um dos tipos especiais de ANN, sendo empregada primeiramente no campo de visão computacional. Possuem um design inspirado no córtex visual dos seres humanos, o qual possui várias células que são responsáveis pela detecção de luz em regiões sobrepostas e pequenas dos campos visuais. Assim, uma CNN consiste em múltiplas camadas convolucionais, cada uma das quais desempenha a função que é processada pelas células no córtex visual (ZHANG; WANG; LIU, 2018). As significativas inovações proporcionadas pelas CNNs têm desempenhado um papel de extrema importância no avanço da visão computacional, o que resulta em notáveis progressos nas mais diversas áreas, inclusive na classificação de imagens e detecção de objetos. Além de suas contribuições para pesquisas teóricas, os cientistas têm se dedicado cada vez mais à aplicação das CNNs em contextos de inspeção industrial, com o objetivo de ampliar seu valor prático, especialmente na detecção de defeitos.

Existem principalmente 4 modelos de ML, aprendizado supervisionado, aprendizado não supervisionado, aprendizado semissupervisionado e Aprendizado por Reforço (RL) (TESHALE et al., 2024). O aprendizado supervisionado consiste no treinamento de algoritmos com base em conjuntos de dados previamente rotulados, aqueles que contêm entradas e saídas correspondentes corretas, permitindo que o modelo aprenda a classificar informações ou prever resultados de forma precisa (ZHANG et al., 2022). Já os algoritmos supervisionados operam sobre dados não rotulados, buscando identificar padrões, estruturas ou agrupamentos com base em semelhanças entre os dados, sem a necessidade de intervenção ou orientação humana (TESHALE et al., 2024). Aprendizado semissupervisionado visa combinar essas duas tarefas ao utilizar dados rotulados e não rotulados, buscando melhorar o desempenho em uma delas, utilizando informações geralmente associadas à outra (VAN ENGELEN; HOOS, 2020). Já algoritmos de RL consiste na interação do algoritmo com o ambiente aprendendo uma política ótima, por tentativa e erro, para problemas de tomada de decisão sequencial em uma ampla gama de campos, como os das ciências naturais e da engenharia (LI, 2017). Para esta pesquisa, foi utilizado o aprendizado supervisionado.

3.6.2. Detecção de objetos

O uso da Visão Computacional (VC) tornou-se um grande aliado no desenvolvimento de pesquisas para a área de automação de processos, sendo que tais sistemas têm a capacidade de poder tomar decisões através de informações tiradas do ambiente (COELHO, 2016). Segundo (COELHO, 2021), não existe um método que seja capaz de resolver todos os desafios, pois eles são específicos de cada aplicação. Assim, o desenvolvimento de tais sistemas em ambientes industriais é um desafio.

A detecção de objetos é um termo geral da área de VC para descrever um grupo de tarefas que envolvem o reconhecimento de objetos em imagens digitais. Tal técnica envolve a identificação e localização de objetos em imagens ou vídeos e pode ser aplicada em diversas situações como detecção de pedestres ou faces por exemplo (ARAÚJO, 2022) Figura 9. Vários são desafios para detecção de objeto, entre eles estão oclusões de ambiente, pouca ou muita iluminação, baixa resolução, cenários noturnos e até a falta dados de amostra (FERRANTE, 2023).



Figura 9: Exemplo de detecção de objetos em imagens (FELZENSZWALB et al., 2010)

Por conseguinte, para se ter uma compreensão completa da imagem não devemos apenas nos concentrar na classificação de diferentes imagens, mas, além disso, tentar estimar com precisão os conceitos e localizações dos objetos contidos em cada imagem. Tal técnica é conhecida como detecção de objetos (DO). Porém, a DO possui 2 problemas: a determinação de onde o objeto está localizado na imagem e a qual classificação pertence. Desse modo, a estrutura dos modelos convencionais de detecção de objetos pode ser categorizada principalmente em três etapas: seleção informativa da região, extração de características e classificação (ZHAO et al., 2019). As CNNs se tornaram o estado da arte em muitas aplicações de visão computacional ao realizar tarefas específicas de aprendizado para classificação e são frequentemente consideradas como o aprendizado de máquina mais influente no campo da visão computacional para classificação, detecção e reconhecimento de objetos em imagens e vídeos (FERRANTE et al., 2021).

3.6.3. *You Only Look Once (YOLO)*

You Only Look Once (Você olha Apenas uma Vez), YOLO, é um popular modelo de detecção de objetos que consegue atingir eficiência e precisão. Em sua versão V4 o YOLO conseguiu atingir precisão e taxa de recuperação de 43 mAP (precisão média), ao processar imagens em um acelerador TFLOP de 15,3 (NVIDIA GTX 1080Ti). Trabalhos como o de (LI et al., 2023) afirmam que tal taxa de processamento é suficiente para atender as demandas da indústria e academia. Dentre as arquiteturas conhecidas, a YOLO é reconhecida como o estado-da-arte para detecção de objetos por ter a estratégia de single-shot, que utiliza a entrada somente uma única

vez para as detecções, permitindo grandes ganhos em desempenho e conseguindo velocidade de detecção. Desde sua primeira apresentação por (REDMON et al., 2016) em 2015, o sistema YOLO já está em sua décima primeira versão, lançada em setembro de 2024.

Em uma atividade de detecção, o objetivo é prever a localização real de cada objeto e a qual classe o mesmo pertence. Para uma CNN como a YOLO isso é feito através de caixas delimitadoras (*bounding box*). Tais caixas serão formadas pelas coordenadas X e Y para formar o ponto inicial e final que será sobreposto na imagem além de sua largura e altura. Cada uma das caixas delimitadoras pode conter uma instância de qualquer objeto (baseado em proposta de região) (FERRANTE et al., 2021). O processo de detecção divide a imagem em diversas grades com dimensões 19 x 19, para versões mais atuais. Para cada uma, o YOLO prevê N possíveis caixas delimitadoras, juntamente com um valor de confiança para diferentes classes por elemento da grade (TERVEN; CÓRDOVA-ESPARZA; ROMERO-GONZÁLEZ, 2023). Assim, o algoritmo estabelece um limiar, ou (*threshold*), da confiança para que as caixas delimitadoras que estiverem abaixo desse limiar são desconsideradas (ARAÚJO, 2022). O processo geral de detecção pode ser observado na Figura 10.

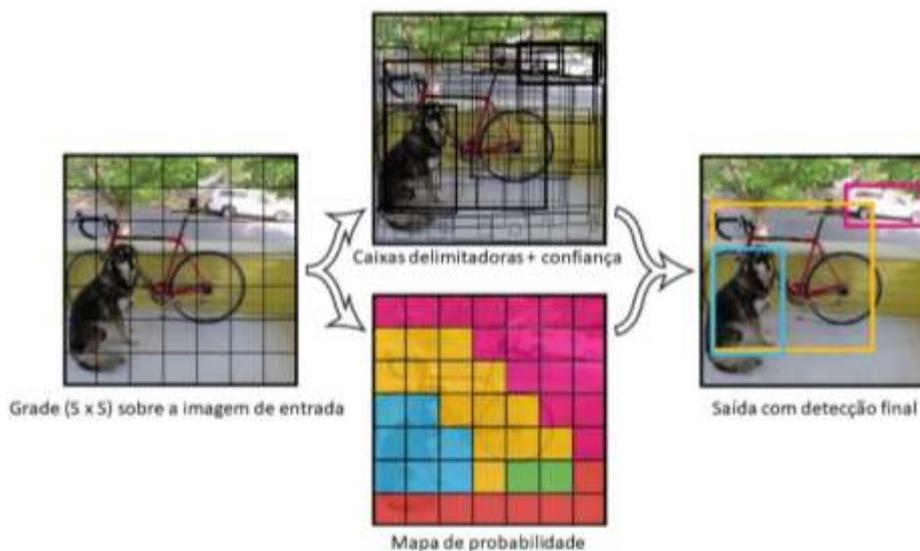


Figura 10: Processo geral de detecção do YOLO (REDMON et al., 2016). Adaptado

3.7. Trabalhos relacionados a detecção de defeitos superficiais em MADA através de CNNs

Apesar do progresso, a técnica de MADA enfrenta severas críticas quanto a estabilidade de seu processo (XIONG et al., 2018). Na soldagem a arco, por exemplo, além das diferenças de início e fim das camadas depositadas, a solidificação da poça de fusão varia com o tempo devido a variação de calor em cada deposição. Tais fatores afetam a qualidade superficial da peça produzida. Com isso, a não garantia de qualidade contribui para desperdício, aumento do ciclo de produção e impede a aplicação em campos avançados com altas exigências de complexidade. Como os processos de MADA são baseados em deposições camada por camada, a qualidade da superfície da camada construída tem uma importância fundamental na qualidade do componente produzido, pois, caso os possíveis defeitos da camada sejam cobertos pela deposição subsequente, podem gerar defeitos internos na peça final, levando a falhas catastróficas (HUANG et al., 2022).

Existem muitas maneiras de detectar defeitos durante o processo de fabricação. A fim de resolver tais problemas, (HE et al., 2021) discutem um novo método de detecção e classificação de defeitos, baseado em imagens magneto-ópticas (MOI), no qual utilizaram informações do campo magnético para testar visualmente a superfície e subsuperfície e, através de uma *cost-sensitive convolutional neural network* (CSCNN), realizaram a inspeção de forma automática e precisa dos defeitos em uma liga de aço de baixo carbono.

No estudo de (CHEN et al., 2021), os autores desenvolveram um sistema de identificação e classificação de defeitos na superfície através de métodos *K-Nearest Neighbours*. Os autores tiveram sucesso na aplicação, usando a Manufatura Aditiva Auxiliada por Laser (MAAL), e obtiveram uma precisão de 93,15%.

Na metodologia proposta por (WU et al., 2023) foi proposto um modelo aprimorado da versão 3 do YOLO, (YOLOv3), para um sistema automático de detecção de defeitos em poças de fusão em tempo real durante o processo, podendo identificar os principais defeitos, incluindo porosidade e escoria, e possuindo uma precisão de 98% e 59 FPS. Já a pesquisa de (LI et al., 2023) otimizou a versão YOLOv4 para aplicação em cordões de passagem única e multipasse e obteve uma velocidade teste de 42 FPS obtendo um mAP de 94,5 no conjunto de teste podendo detectar vários defeitos em diferentes matérias. Outra aplicação interessante do

YOLO no domínio da MADA é apresentada por (LI et al., 2022), no qual os autores aplicam o sistema para a detecção de posição de componentes soldados e defeitos de soldagem na superfície entre camadas. O sistema proposto tem 53% de precisão na detecção de anomalias e 100% de precisão para identificação da localização dos componentes, de tal forma que tais informações fornecem uma avaliação com alta precisão de qualidade das camadas depositadas.

Já o trabalho de (SO et al., 2022) propôs uma metodologia para prever a rugosidade e conseqüentemente melhorar a qualidade final dos produtos feitos por MADA através da análise de dados. Utilizando-se de vários métodos de análise, como redes neurais e pré-processamentos combinados, o trabalho proposto se utilizou da soldagem a arco de gás tungstênio (GTAW) por transferência de metal frio (CMT) para formar as peças obtendo precisão de predição com uma eficácia de 98 %.

No estudo proposto por (KUMAR; JAIN, 2022) um aprendizado de máquina usando o KNN (K-vizinhos mais próximos) foi usado. para prever a rugosidade superficial. Através do processo μ -PTAMAM (fabricação aditiva de metal por arco de transferência de microplasma). Os resultados mostram que o erro de previsão foi de -6,2 a 2,8% para a forma de pó e -5,8 a 2,3% para a forma de fio do material, o que comprova a capacidade do KNN para essa tarefa.

Com um modelo matemático com base em uma rede neural artificial direta (FANN) concebido por (HU et al., 2020) foi possível prever a geometria do cordão fabricado e, com base nesses dados, uma interação combinada entre o modelo FANN e um algoritmo genético (FANN-GA) foi desenvolvido para prever os parâmetros do processo de soldagem tendo como entrada a geometria desejada do cordão e altura da camada. Através de vários experimentos, conduzidos com base em um planejamento fatorial completo, foi possível validar o algoritmo criado obtendo um erro médio entre as variáveis desejadas (largura, altura e área) e as reais de 3,12%, 4,63% e 1,58% respectivamente. Já para a construção de múltiplas deposições, a variação de altura da peça foi 8,33%.

Nesta secção, foi possível observar algumas abordagens para detecção de defeitos nos sistemas de MADA e como tais abordagens influenciam os parâmetros do sistema. Para o presente trabalho foi utilizada a arquitetura YOLO, em sua versão V8.

4. MATERIAIS E MÉTODOS

Nessa secção será abordado os materiais utilizados na pesquisa, bem como a metodologia aplicada para alcançar os objetivos previstos. Toda as amostras construídas foram fabricadas no Laboratório de Soldagem (LabSol) da Universidade Federal de Campina Grande.

4.1. Caracterização da pesquisa

Essa investigação abrange disciplinas no campo da engenharia mecânica, de processos de fabricação e de Inteligência Artificial, adotando uma abordagem teórico-experimental com o objetivo de aprimorar os fundamentos teóricos e pesquisas correlatas. Os parâmetros utilizados na pesquisa foram escolhidos em função da revisão bibliográfica dos principais trabalhos disponíveis sobre inclusão de defeitos em MADA utilizando a liga 316L-Si.

Após a estipulação dos parâmetros e níveis do processo de deposição de camadas, procedeu-se com a construção das paredes utilizando o método de MADA em um substrato de aço ASI 1015. Logo após cada parede ser construída várias imagens foram fetias para construção do *dataset* e para treinamento posterior.

Para esta pesquisa foi criado um banco de dados de imagens para o reconhecimento dos seguintes defeitos: *Humping*, porosidade superficial e inclusão de escória superficial.

4.2. Dependências e Hardware utilizados no treinamento

O hardware utilizado nesse trabalho para criação e desenvolvimento do algoritmo foi um notebook Acer Nitro 5, com um processador Intel core i5 2,4 Ghz, contendo uma 8 Gb de memória RAM e uma GPU NVIDIA Gforce GTX 1050 de 4Gb. Além disso, os códigos foram desenvolvidos na IDE PyCharm versão 3.10.

4.3. Materiais

Neste trabalho foi utilizado como metal de adição o arame ER316LSi com diâmetro de 1,2 mm, as informações da composição do arame juntamente com o substrato que foi o aço ASI 1015 com dimensões de 170 mm por 160 mm por 19,54 mm, estão na Tabela 2. O gás de proteção utilizado foi argônio 99,8 %.

Tabela 1: Composição química do arame e substrato (Autoria própria)

	Fe	C	Mn	Si	P	S	Cr	Mo	Ni	Cu
Substrato	Bal.	0,148	0,419	-	-	-	0,043	-	-	-
Arame	Bal.	0,03	1,75	0,83	0,03	0,03	19	2,5	12,5	0,75

4.4. Manipuladores Robóticos

Com o uso de um manipulador CNC de 3 eixos, disponível no laboratório de Soldagem da Universidade Federal de Campina Grande (UFCG), foi possível promover um estudo da viabilidade do processo no desenvolvimento de peças baseadas na MADA. Assim, devido a possibilidade de construção de peças via MADA a robótica aparece como uma opção para facilitar o manuseio da tocha automaticamente.

O Robô de 3 eixos foi controlado pelo software *MACH3* para CNC (Controle Numérico Computadorizado) com uma linguagem baseada no código G no qual um código para realizar os caminhos da peça foi criado. A construção foi realizada usando o processo GMAW. A fonte de soldagem usada foi a *Digiplus A7* da IMC soldagem configurada no modo de transferência de Curto-Circuito controlado. O sistema robótico, apresentado na Figura 11, foi responsável pelas seguintes funções: controle da tocha GMAW, ajuste dos parâmetros, controle de movimento da tocha e execução dos códigos desejados.

Na imagem podem ser vistos os seguintes componentes:

1. Controle do arame
2. Cilindro de Gás
3. Tocha
4. Fonte de soldagem
5. Parede fabricada por MADA
6. Mesa de trabalho



Figura 11: Configuração experimental do robô MADA (Autoria própria)

4.4.1. Software Mach3 para controle da CNC

Na fabricação utilizando máquinas CNC a escolha do sistema de controle é de fundamental importância. Nesse sentido, um sistema de feedback se apresenta como uma opção ideal, pois oferece alta precisão e exatidão em sistemas de movimento com múltiplos eixos. O *Mach3*, um software comercial, é projetado especificamente para controlar os eixos de máquinas CNC, através da interface de usuário de um computador, e oferece recursos tanto em malha aberta quanto fechada. Este programa permite a movimentação dos eixos tanto manualmente quanto por programação G-Code (MEZA et al., 2018). A Figura 12 apresenta a tela principal do *Mach3*.

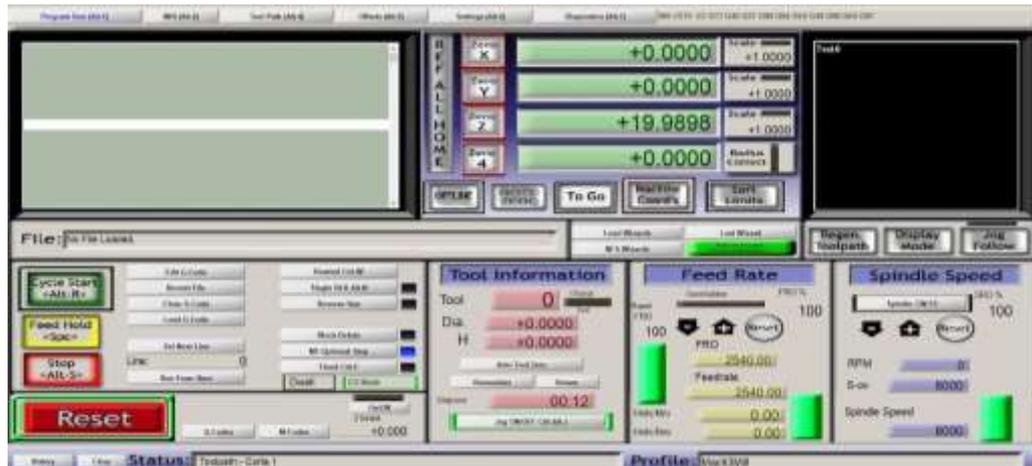


Figura 12: Tela principal do Mach3 (Autoria própria)

4.5. Estratégia de deposição

As amostras foram feitas usando um caminho aberto para construção de paredes de 100 mm de comprimento sendo que a altura variou um pouco de acordo com as paredes depositadas. Usando o método alternado de deposição ou ZIG-ZAG, no qual após cada camada a direção da deposição é invertida ao longo da linha central do substrato (ZHANG et al., 2018). Essa estratégia é ilustrada na Figura 13.

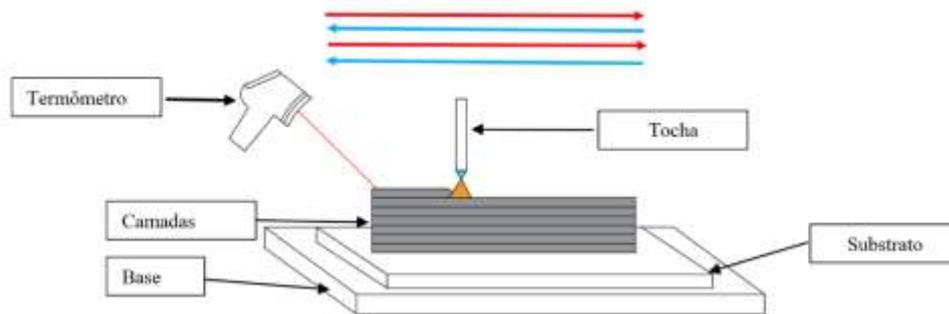


Figura 13: Estratégia de deposição ZIG-ZAG (Autoria Própria)

4.6. Coleta de dados

Para criação dos bancos de dados utilizado nessa pesquisa, procedeu-se semelhante a outros processos de manufatura aditiva, no qual os passos incluem o planejamento da trajetória e a deposição do material sobre o substrato. Foram depositadas inicialmente 12 paredes, sendo as mesmas fabricadas com inclusões propositalmente de defeitos, conforme Tabela 2, enquanto os parâmetros fixos utilizados

nos experimentos estão na Tabela 3. Durante o processo de fabricação, após a deposição de cada camada, imagens da superfície depositada são tiradas com uma câmera de celular iphone 13 de 12 MP em diversas configurações para obter imagens frontais, traseiras, laterais e superiores. A distância de cada imagem para parede vario entre 10 cm e 15 cm.

Tabela 2: Divisão das inclusões de defeitos nas paredes fabricadas (Autoria própria)

Experimentos	Paredes construídas
<i>Humping</i>	1 - 4
Porosidade	5 - 8
Respingos	9 – 12

- *Humping*: Para inclusão desse defeito foram realizadas deposições com alta velocidade de soldagem, de 500 mm/min e 600 mm/min.
- Porosidade: Já para inclusão do defeito de porosidade, foram utilizados pouca vazão de gás, foram elas de 0 L.min⁻¹ e 10 L. min⁻¹.
- Respingos: A superfície das camadas não foi limpa após cada deposição e obteve-se também esse defeito com as altas velocidades de soldagem usadas no defeito de *Humping*, ou seja, com altas velocidades de soldagem.

Tabela 3: Parâmetros fixos utilizados nos experimentos (Autoria própria)

Parâmetros	Valor
Gás de proteção	Argônio 99,8%
Velocidade de Alimentação do Arame	4 m/min
Corrente de Pico	250 A
Diâmetro do Arame	1,2 mm
DBCP	20,00 mm

4.7. Técnicas de aumento de dados artificialmente

Na visão computacional, para se ter uma melhor robustez e melhorar a aprendizagem de com um número limitado de exemplos de treinamento, são amplamente utilizadas técnicas de aumento de dados artificialmente. O aumento de dados é uma série de estratégias para ampliar e melhorar o tamanho e a forma de uma imagem, mantendo o rótulo (ZHANG et al., 2021). No processamento de imagens, os dados de treinamento são aumentados, por exemplo, por inversão horizontal, corte aleatório, inclinação e alteração dos canais RGB das imagens originais (FADAE; BISAZZA; MONZ, 2017). Sendo assim, o aumento de dados resolve duas preocupações dos pesquisadores: primeiro, gerar mais dados a partir de uma quantidade limitada e, segundo, minimiza o *overfitting* (MAHARANA; MONDAL; NEMADE, 2022). Para este trabalho, todas as imagens obtidas foram submetidas as técnicas descritas a seguir.

4.7.1. Flipping

A imagem pode ser invertida horizontalmente ou verticalmente. Ele produz imagens espelhando a imagem em múltiplos de 90 graus. Embora existam estruturas que não suportam inversão vertical. A inversão vertical pode ser feita girando a imagem em 180 graus e depois realizando uma inversão horizontal. Esta técnica de aumento preserva rótulos em conjuntos de dados como CIFAR-10 e Imagenet. Porém os conjuntos de dados que envolvem reconhecimento de dígitos, não são comprovados como uma transformação que preserva o rótulo (KHOSLA; SAINI, 2020). Um exemplo de *flipping* pode ser visto na Figura 14.



Figura 14: Técnica de Flipping (Autoria própria)

4.7.2. Rotação

Dependendo da necessidade, a imagem pode ser girada em ângulos de 90° ou orientada em ângulos mínimos, Figura 15.



Figura 15: Técnica de Rotação (Autoria própria)

4.7.3. Aplicação de filtro Gaussiano

Uma das técnicas muito úteis em processamento de imagens é o filtro gaussiano 2D, principalmente na suavização imagens. O filtro gaussiano é um operador de convolução 2D usado para suavizar imagens e remover ruído (CABELLO et al., 2015). Ele considera principalmente a distância espacial entre pixels durante a amostragem (ZHANG et al., 2021). A aplicação do filtro gaussiano pode ser vista na Figura 16.



Figura 16: Aplicação de filtro Gaussiano (Autoria própria)

4.7.4. Aplicação de filtro de contraste e alteração de brilho

Outra técnica de realce que pode melhorar as imagens utilizadas é a de contraste adaptativo. Em especial, a equalização adaptativa de histograma com limitação de contraste (*Contrast Limited Adaptive Histogram Equalization – CLAHE*). Esse algoritmo, através de um histograma, realiza a coleta em pequenas regiões da imagem e efetua a equalização somente nesta área, permitindo então, que imagens que possuem variação de intensidade possam ter o seu contraste melhorado (KEGLEVICH; ANDRIJAUSKAS, 2024).

Outra técnica relacionada a alteração do realce de imagens é a alteração do brilho da imagem da biblioteca *PIL*. O ajuste de brilho altera o nível de brilho das intensidades RGB e pode ser usado tanto para aumentar o brilho da imagem quanto para diminuí-lo (HADI et al., 2016).

4.7.5. Cropping

Crooping, também conhecido como corte aleatório, Figura 17, diz respeito a destaque de uma seção específica da imagem para, posteriormente, essa seção ser redimensionada para corresponder ao tamanho da imagem original. Essa porção mantém as características da imagem original e, se necessário, a imagem é redimensionada para uma determinada escala (KHOSLA; SAINI, 2020). Essa técnica de aumento possui a vantagem de poder ser usada mais de uma vez, já que cada imagem gerada é diferente uma da outra.



Figura 17: Técnica Cropping (Autoria própria)

4.8. Computer Vision Annotation Tool (CVAT)

O CVAT, Figura 18, é uma ferramenta gratuita de anotação de imagem e vídeo de código aberto baseada na WEB para a rotulação de dados para algoritmos que usam visão computacional. Através dessa ferramenta, foi possível a marcação das *bounding boxes* no dataset das imagens. Com o CVAT, após o término das marcações, foi possível a exportação dos arquivos necessários para aplicação no treinamento do YOLO. Os arquivos resultantes das exportações são arquivos de formato *txt*, os quais possuem as coordenadas e tamanho das *bounding boxes* e são nomeadas cada um referente ao nome da imagem a qual tais coordenadas pertencem.

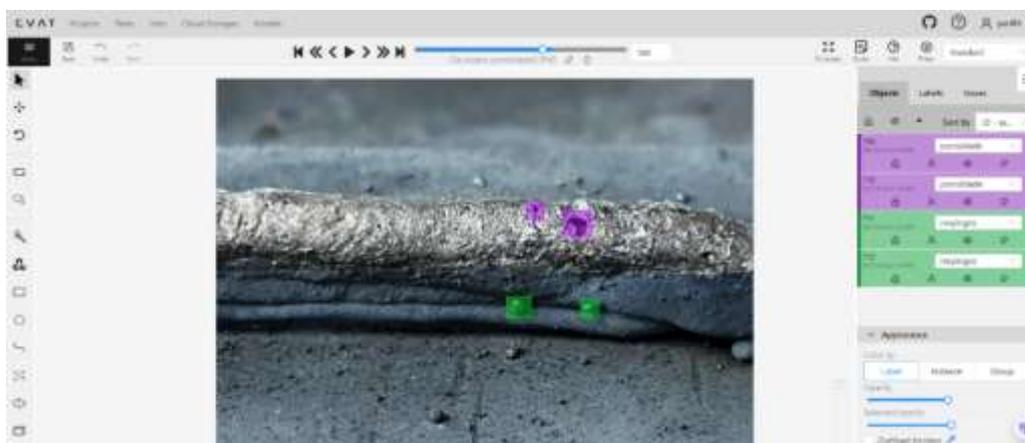


Figura 18: Interface do CVAT (Autoria própria)

4.9. Concepção dos bancos de dados

Para este trabalho foram concebidos três banco de dados. Cada banco de dados passou por diferentes experimentos de treinamento e validação para se encontrar o melhor modelo de detecção. As imagens das paredes foram retiradas se utilizando de um celular *iphone 13*, com uma câmera de 12 Mp e uma resolução de 4000 x 3000 pixels. Na tabela abaixo, encontra-se o número total de imagens para cada banco de dados. Em relação ao banco de dados B3, o mesmo foi concebido como tentativa de aumentar a acurácia e precisão da detecção do defeito de porosidade. Para tanto, foi necessário a construção de novas paredes com esse defeito. Os três bancos de dados estão disponíveis através do link: https://drive.google.com/drive/folders/1k-GPUDfwQGPrxMDQbgB2_cW0hfQbK3qQ?usp=sharing, disponível no *Google Drive* ou link da plataforma *kaggle* disponível em:

<https://www.kaggle.com/datasets/yuriemanoel/defeitos-superficiais-em-manufatura-aditiva-b1>.

Tabela 4: Quantidade de imagens para cada banco de dados

Banco de dados	Quantidade de Imagens					
	Humping		Porosidade		Respingos	
	Treino	Validação	Treino	Validação	Treino	Validação
B1	500	100	600	150	300	50
B2	1008	342	1175	310	1092	100
B3	1164	342	1400	300	1100	211

4.10. Detecção baseada no algoritmo para treinamento do YOLO

O método de detecção foi realizado com três etapas. A primeira etapa foi a criação/aquisição de um conjunto de dados rotulados com imagens dos defeitos (B1) juntamente com o aumento artificial. Após, foi realizado o um novo aumento artificial do banco de dados B1 para criação do *dataset* (B2) e, posteriormente, foram tiradas mais fotos de defeitos para concepção de (B3), principalmente de mais imagens de porosidade. Para aplicação no algoritmo do YOLO, o banco de dados foi dividido em dois grupos, treino e validação, e, logo após, este trabalho conduziu um experimento de teste para comparação dos 3 trabalhos, conforme também realizado no estudo de (WU et al., 2023). Nesse sentido, o banco de dados de teste continha 853 imagens.

O grupo de imagens de treino foi usado para o treinamento propriamente dito. Já as de validação são as imagens avaliadas durante o treinamento que não entram para o cálculo de perda, sendo de extrema importância para a observação do aprendizado da rede, já que, no caso do YOLO, o algoritmo gera resultados aplicando métricas de desempenho sobre esses dados. Ao final, os modelos também foram testados com uma câmera em uma aplicação real. Além disso, outras bibliotecas foram utilizadas para concepção deste projeto, dentre elas estão:

- OPEN CV → Para leitura e processamento de imagens e vídeos.
- Matplotlib → Popular biblioteca de visualização e criação gráfica.
- OS → Biblioteca de comandos do sistema operacional.

- PIL → Pacote para manipulação de imagens.

As configurações do treinamento para o *YOLO* devem ser sempre modificadas de acordo com os dados e o número de classes utilizados. Tais configuração são os hiperparâmetros e são definidos antes do processo de treinamento de um modelo de aprendizado de máquina. A escolha correta dos hiperparâmetros pode ter um impacto significativo no desempenho e eficiência do modelo. Assim, como neste trabalho foram realizadas as seguintes alterações, com base nas informações do trabalho de (REDMON et al., 2016).

- *Steps*: Indicam em qual dos lotes as taxas de aprendizado serão atualizadas. São calculadas conforme abaixo:

$$\textit{Step 1} = 80\% \textit{ de Max batch}$$

$$\textit{Step 2} = 90\% \textit{ de Max batch}$$

- *Filters*: Alteração do número de filtros apenas nas camadas de convolução, e definido conforme abaixo;

$$(n^{\circ} \textit{ de classes} + 5) * 3$$

O resultado de cada item é apresentado abaixo:

Steps = 4800, 5400

Filters = 24

Os treinamentos realizados continuam 300 épocas, esse número foi escolhido inicialmente para teste do código, de acordo com recomendações do site <https://docs.ultralytics.com/pt>, criadores da versão 8 do *YOLO*. No contexto do *YOLOv8* as imagens foram divididas em cerca de 80% para treino, 20% para validação para cada banco de dados.

Logo após o treinamento da rede, com o objetivo de ensinamento de todo o banco de dados para rede neural, teve-se início o processo de validação. Caso o processo de validação fosse um valor abaixo do esperado, seria necessário ajustes no treinamento e/ou banco de dados visando um aumento de precisão. Tais ajustes variam bastante, podendo ser aumento do banco de dados com construção de mais amostras, imagens de melhor qualidade ou inclusão de mais estratégias de aumento

artificial. A última etapa do processo, o teste, é realizado com imagens aleatórias e seu desempenho deve seguir os passos anteriormente obtidos nos passos anteriores.

O processo de aplicação do YOLO, uma rede neural, pode ser trabalhoso e longo, pois, em várias ocasiões, aplicações de CNN's se tratam de processos cíclicos com vários tipos de ajustes para se encontrar o melhor resultado possível. A Figura 19 apresenta o fluxograma desse processo de criação do bando de dados e treinamento. A Figura 20 apresenta o processo de aplicação da rede neural.



Figura 19: Fluxograma do processo de criação do banco dados (Autoria própria)



Figura 20: Processo de aplicação da rede Neural utilizada (Autoria própria)

Com o objetivo de melhoria de velocidade de aprendizado, foi utilizado a estratégia conhecida como *Transfer learning*, aprendizado por transferência, com modelos pré-treinados sobre o conjunto MS COCO, a qual também foi usada no trabalho de (FERRANTE, 2023). Essa técnica permite que modelos já treinados possam ser usados em novas tarefas relacionadas ao aprender os primeiros filtros de convolução de forma rápida.

Foi aplicada a técnica de *autotuning*, a qual é um processo automatizado de ajuste de hiperparâmetros em modelos de aprendizado de máquina com o objetivo de melhorar seu desempenho. Em vez de ajustar manualmente os cada parâmetro, o *autotuning* utiliza algoritmos que exploram diferentes combinações de hiperparâmetros de forma sistemática para encontrar a configuração ideal que melhora a performance do modelo em um determinado conjunto de dados. Nesse contexto, O YOLO oferece um algoritmo para fazer o *autotuning* em número de interações, ou seja, em cada interação, o YOLO vai percorrer o número de épocas escolhido com determinada configuração de hiperparâmetros, para, no final, escolher a que melhor performou o conjunto de dados de validação. Assim, o conjunto de hiperparâmetros pode ser utilizado no novo treinamento. Para este trabalho, foi utilizado 30 interações.

4.11. Interface Homem Máquina (IHM)

Para desenvolvimento deste projeto foi concebida uma IHM para interação com o processo de detecção e classificação de defeitos. As IHM's são amplamente usadas em equipamentos industriais para várias tarefas paralelas. Desempenham um importante papel na automatização de sistemas permitindo o acompanhamento das atividades pelo usuário. Neste trabalho, a IHM foi desenvolvida por *Python*, através da biblioteca *TKinter* que possui uma gama de componentes para o desenvolvimento de interfaces gráficas. O motivo da criação de uma IHM para este trabalho foi o fato dos trabalhos pesquisados, mencionados na seção 3.7, não terem desenvolvido tal ferramenta, embora todos os trabalhos mencionados tenham sido de grande importância para a academia.

A interface do sistema criada para este trabalho apresenta um design simples e intuitivo, com funcionalidades acessíveis tanto para usuários iniciantes quanto para especialistas. O processo de upload de imagens é facilitado por botões claramente

identificados, permitindo que os usuários carreguem imagens rapidamente ou inicie a detecção on-line sem complexidade. As Figuras a seguir apresentam os passos de cada aba da IHM criada bem como a função de cada componente na tela. A IHM criada tem a capacidade de ser flexível, pois as detecções vão depender dos pesos que são selecionados. Desse modo, a mesma funciona para qualquer treinamento que tenha como base a estrutura YOLO.

4.11.1. Detecção Off-line

Faz a detecção e classificação em um banco de dados escolhidos pelo usuário com base no peso selecionado. Figura 25.

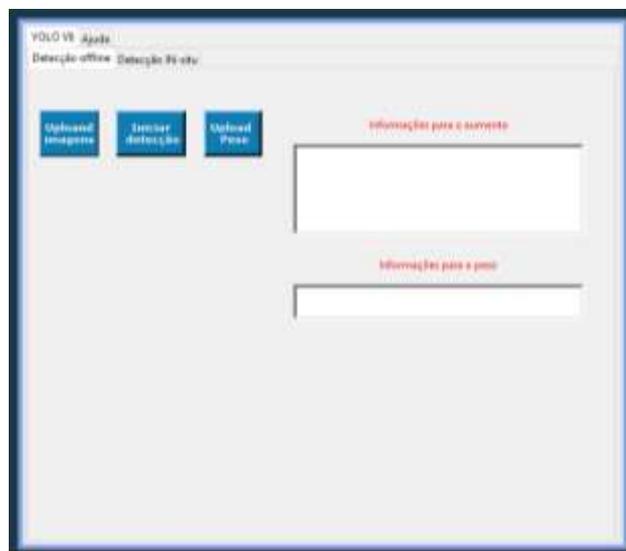


Figura 21: Interface de interação para detecção de defeitos Offline (Autoria própria)

- Upload → Abre uma pasta de procura para fazer upload de uma imagem;
- Upload peso → Abre uma pasta para selecionar o arquivo de peso de extensão .pt. No Caso deste trabalho, foi utilizado o peso best.pt para cada banco de dados.
- Iniciar → Inicia o algoritmo de detecção de defeitos nas imagens baixadas com os dados do peso selecionado;

4.11.2. Detecção In-situ

Faz a detecção e classificação a partir dos dados de entrada de uma câmera também com base no peso selecionado. Assim, no momento que o usuário clica em “Iniciar detecção in-situ”, uma imagem da câmera é aberta e, a partir das informações do peso escolhido, a detecção e classificação tem início. Também é possível aplicação

de até 2 câmeras para detecção, nesse caso as câmeras podem ser colocadas em locais diferentes para uma maior flexibilidade de detecção. Figura 26.

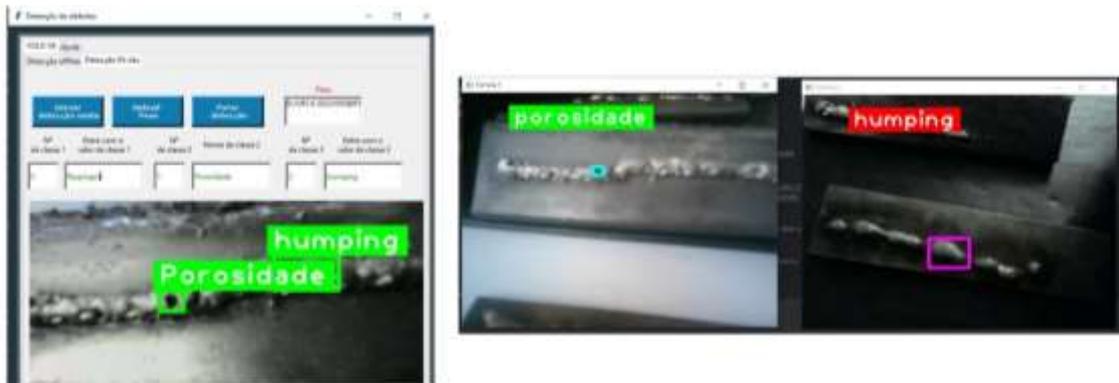


Figura 22: Interface de interação para detecção de defeitos in-situ (Autoria própria)

- Upload peso → Abre uma pasta para selecionar o arquivo de peso de extensão .pt.
- Iniciar → Inicia o algoritmo de detecção de defeitos nas imagens baixadas com os dados do peso selecionado;
- Entre com o valor da classe → Serão colocados os nomes das classes pretendidas. Aqui, o valor se atualiza conforme o usuário o muda.
- N° da classe → Aqui é colocado o valor numérico correspondente ao nome da classe escolhido.

4.11.3. *Aba de ajuda*

Contém informações importantes sobre todas as funcionalidades da IHM como por exemplo funções de todos os botões e explicações sobre o YOLO e posicionamento de câmeras.

4.12. *Métricas de Avaliação*

As Métricas de Avaliação desempenham um importante papel na obtenção de um classificador ideal durante um modelo de detecção de objetos em imagem. Assim, a seleção de métricas de avaliação adequadas é uma importante chave para obter o classificador ideal. No contexto de ML, a avaliação serve a dois propósitos: os métodos que não possuem desempenho aceitável podem ser descartados e, em contrapartida, os que possuem um desempenho promissor podem ser usados e otimizados. Normalmente, as métricas de avaliação utilizadas em modelos de CNN's são: *precision*, *recall*, *average precision (AP)* e *median average precision (mAP)* e F1

score. Assim, para o entendimento dessas métricas utilizadas é necessário o conhecimento do conceito de Matriz de confusão:

Tabela 5: Matriz de Confusão

		Imagens Detectadas	
Imagens Reais		Verdadeiro Positivo (TP)	Falso Negativo (FN)
		Falso Positivo (FP)	Verdadeiro Negativo (TN)

- *True positive (TP)*, ou Verdadeiro Positivo, ocorre quando a classe procurada é prevista corretamente.
- *False Positive (FP)*, ou Falso Negativo, ocorre quando a classe procurada é prevista de forma incorreta.
- *True Negative (TN)*, ou Verdadeiro Negativo, ocorre quando a classe que não está sendo procurada é prevista corretamente.
- *False Negative (FN)*. Ou Falso Negativo, ocorre quando a classe que não estamos procurando é prevista incorretamente.

Todas essas métricas foram aplicadas nos dados de validação, tanto no Dataset (B1) quanto no (B2). Por conseguinte, o significado de cada métrica utilizada nesse trabalho está apresentado abaixo:

- *Precision*, precisão, é a medida de exatidão das previsões positivas do modelo. É calculado conforme a equação abaixo.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

- *Recall* é medida do modelo de encontrar todos os casos relevantes, ou seja, a proporção dos verdadeiros positivos em relação aos casos positivos reais.

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

- A *mean Average Precision (mAP)* é comumente utilizada para avaliação da qualidade de modelos de detecção de objetos. A *AP* fornece uma medida da qualidade das previsões de um modelo para uma classe de objeto específica e a *mAP* resume a precisão do modelo em detectar objetos de várias classes.

$$AP = \frac{\Sigma Precision}{N (Total\ de\ imagens)} \quad (3)$$

$$mAP = \frac{\Sigma AP}{N (Total\ de\ classes)} \quad (4)$$

- *F1 score* é a média harmônica entre precisão e *recall*, oferecendo uma avaliação equilibrada do desempenho do modelo ao levar em conta tanto os falsos positivos quanto os falsos negativos. É uma boa forma de monitorar e ajustar o equilíbrio entre identificar corretamente os objetos e evitar a identificação de falsos objetos.

$$F1\ score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (5)$$

5. Resultados e Discursões

Este trabalho teve como objetivo a identificação, classificação e monitoramento *on-line* na fabricação em MADA através da aplicação de uma Rede Neural Convolucional, YOLO, detecção dos defeitos superficiais: *Humping*, porosidade superficial e inclusão de escória. Assim, neste capítulo, são apresentados e discutidos todos os resultados obtidos através da metodologia do capítulo anterior.

5.1. Inspeção Visual

Inicialmente, após aquisição de imagens, foram realizadas inspeções visuais em cada uma das amostras depositadas para verificação dos defeitos para o posterior treinamento. Como exemplo de comparação, a Figura 21 apresenta uma amostra com poucos defeitos superficiais, apresentando apenas as ondulações típicas do processo de MADA e pouca incidência de respingos. Tal amostra, por inspeção visual superficial, apresenta boa qualidade e aparência visual, com ausência de porosidade e efeito de *humping*.



Figura 23: Vista frontal da parede (Autoria própria)

5.1.1. Inspeção Visual (*Humping*)

As paredes de 1 a 4 foram fabricadas alterando a velocidade de soldagem, sendo que os demais parâmetros foram mantidos estáveis. Para esse experimento as paredes 1 e 2 foram fabricadas com 500 mm / min e as restantes, 2 e 3, com 600 mm / min. As 3 primeiras camadas apresentaram o defeito de forma mais visível, porém, a partir da quarta camada, o efeito começou a se dispersar nas deposições da parede 1 e se tornaram menos visíveis. Na parede 3 o fenômeno começou a ficar menos visível a partir da camada 4. A Figura 22 apresenta esse efeito para a parede 1. Conforme também visto por (YUAN et al., 2020), um TS alto tem um grande impacto na formação de *Humping*. Desse modo, também de acordo com o autor, ao passo que a TS aumenta, a poça fundida também aumenta, porém diminui em profundidade, tendo como resultado a formação do defeito.



Figura 24: Efeito da transição do *Humping* da parede (Autoria própria)

5.1.2. Inspeção Visual (*Porosidade*)

As paredes 5 – 8 foram fabricadas alterando-se a vazão do gás para se ter o fenômeno da porosidade. As paredes 5 e 6 usaram 10 L.min⁻¹ e as paredes 7 e 8 usaram 0 L.min⁻¹ de vazão do gás além de nesses experimentos o substrato nem as superfícies das camadas anteriores serem limpas. Como defeitos dos poros são caracterizados pela superfície afundada e são muito pequenos foi difícil para o algoritmo fazer o reconhecimento. A maior quantidade de porosidade superficial foi encontrada nas paredes fabricadas com vazão 0 L.min⁻¹ Figura 23, pois em cada

camada havia porosidade, a qual era coberta pela deposição seguinte. Desse modo, a parede ficava com defeitos internos e com as propriedades mecânicas deficientes.



Figura 25: Defeito de porosidade da parede (Autoria própria)

5.1.3. Inspeção Visual (Inclusão de escória)

O defeito de inclusão de escória foi colocado pela não limpeza do substrato, além de ter também sido encontrada nas paredes fabricadas com o defeito de porosidade e *Humping*. Foi o defeito mais difícil para inclusão. Também sendo um dos mais difíceis para ser lido pelo algoritmo, pois a quantidade de imagens para o treino tinha poucos alvos com respingos. Possivelmente, serão fabricadas mais paredes com este defeito para inclusão nos treinos posteriores.



Figura 26: Defeito de Inclusão de escória da parede 9 (Autoria própria)

5.2. Desempenho dos modelos treinados

Inicialmente, antes da aplicação *on-line* in situ, foi realizada a aplicação do algoritmo nos dados de validação de ambos os bancos de dados para verificação de acurácia. Assim, o treinamento com imagens reais gerou diversos desafios, pois existem variáveis como: diferença de cores, má preparação das imagens diferença de resoluções e diferença de iluminação do banco de dados. Desse modo, ao se utilizar as métricas, é possível avaliar e comparar o desempenho de modelos de aprendizagem de máquina e análise de dados, ou seja, servem como indicadores para o entendimento de o quão bem o modelo criado está realizando as atividades de

previsão e reconhecimento. Desse modo, cada banco de dados passou por alguns testes de treinamento, os quais variaram alguns parâmetros.

O Algoritmo do YOLO cria uma pasta com vários resultados pertinentes para avaliação dos modelos treinados. Através de aplicações da biblioteca do Opencv em pyrhon e de outros resultados recebidos do YOLO foi possível verificar graficamente e numericamente as métricas dos treinos em ambos os bancos de dados.

No geral, em sistemas de detecção de defeitos, existe uma grande vantagem em querer um nível alto de *recall*. Isso é devido à quando se tem um sistema com alto recall, mas com baixa precisão, o modelo retorna à maioria dos itens, porém a proporção de resultados retornados com rótulos verdadeiros é baixa. Assim, em contrapartida, um sistema com alta precisão, mas um baixo *recall* retorna poucos itens, contudo a maioria dos rótulos que foram previstos estão corretos. Desse modo, é preciso escolher o modelo que se adeque melhor para cada uso. No caso desta pesquisa é melhor que se tenha um modelo com um *recall* mais alto, pois, assim, os defeitos ainda poderiam ser identificados, mesmo se não fossem classificados corretamente. Nas tabelas 6, 7 e 8 estão os cálculos das métricas, com e sem *tuning*, para B1, B2 e B3 respectivamente. Nesta etapa, o aprendizado por transferência utilizou os pesos pré-treinados yoloV8n.pt.

Tabela 6: Métricas para o Banco de Dados B1 com e sem Tuning

	Precisão		Recall		mAP	
	S/Tuning	Tuning	S/Tuning	Tuning	S/Tuning	Tuning
Respingos	72,8	72,9	82	79,7	82,8	79,1
Porosidade	65,3	66,1	32,8	33,4	43,1	43,4
Humping	92,3	91,9	97,6	97,6	98,3	98,4

Tabela 7: Métricas para o Banco de Dados B2 com e sem Tuning

	Precisão		Recall		mAP	
	S/Tuning	Tuning	S/Tuning	Tuning	S/Tuning	Tuning
Respingos	59,7	71,7	63	58,7	62,4	64,5
Porosidade	56,5	60,9	29,9	31,9	34,1	38,6
Humping	91,8	92,5	89,7	88,8	93,4	92,1

Tabela 8: Métricas para o Banco de Dados B3 com e sem Tuning

	Precisão		Recall		mAP	
	S/Tuning	Tuning	S/Tuning	Tuning	S/Tuning	Tuning
Respingos	72	60,3	55,4	63,2	62,5	63,9
Porosidade	61,7	64,9	38,9	37,1	43,3	44,4
Humping	89,8	90,5	89,3	90,7	91,4	92,2

Conforme pode ser visto, o dataset de validação do banco de dados B1 e B2 continham menos imagens em relação a B3. Isso pode gerar dificuldade na escolha do melhor modelo, menor generalização e *overfitting* no qual o modelo aprende a se adequar excessivamente ao conjunto de treinamento, porém com desempenho fraco em novos dados ou em situações reais. Assim, os pesos escolhidos foram os dos treinos com *autotuning*, pois tiveram melhores desempenhos gerais.

Os resultados experimentais da função de perda por épocas são mostrados na Figura 27. De acordo com as curvas de perdas, é possível perceber que o banco de dados B1 converge mais rapidamente.

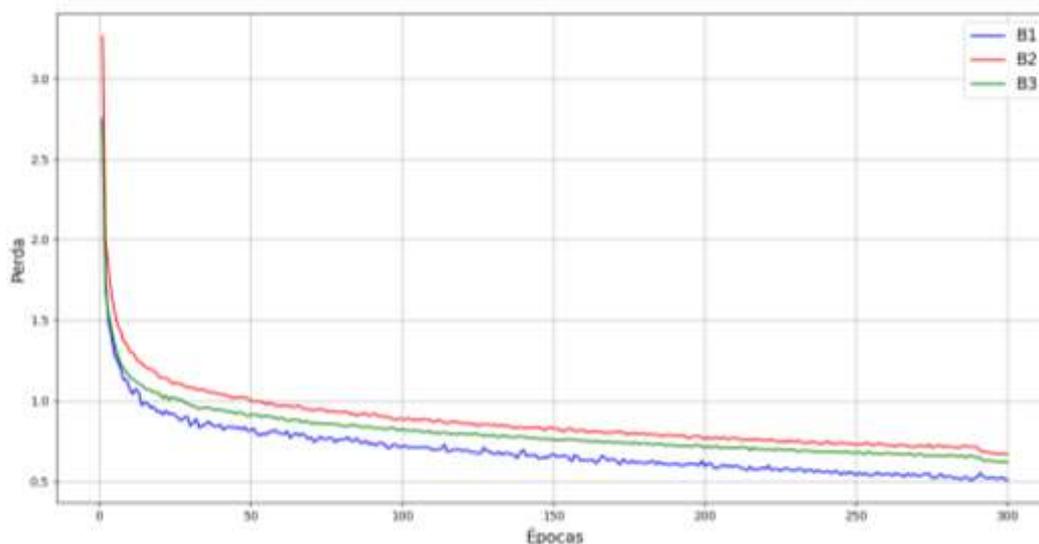


Figura 27: Curva da função de perda do treinamento por épocas (Autoria Própria)

Já para os dados de validação, a figura 28 apresenta o desempenho dos modelos de cada banco de dados.

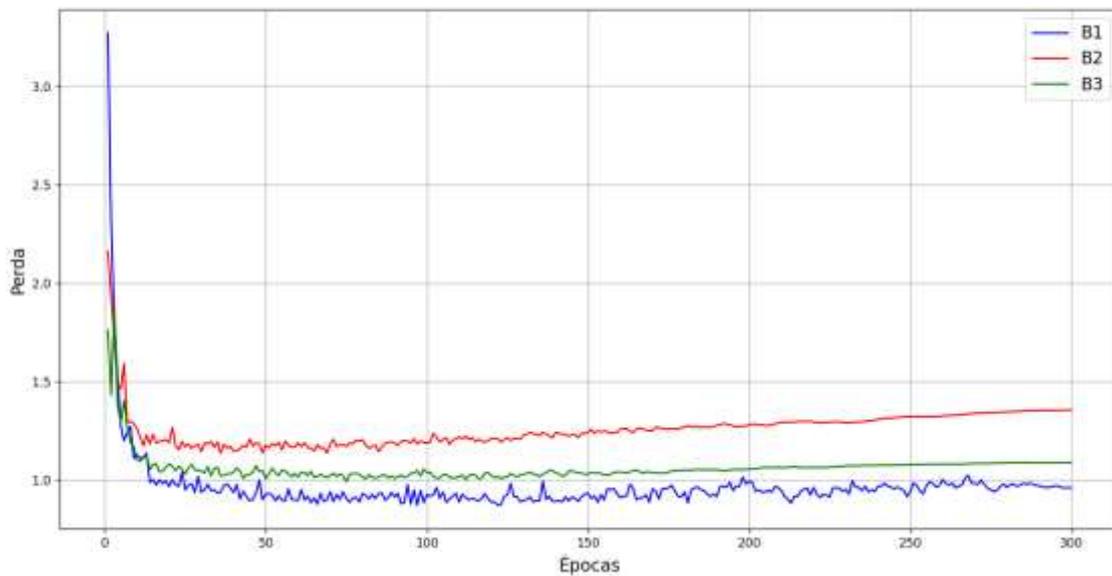


Figura 28: Curva da função de perda da validação por épocas (Autoria Própria)

Pela análise gráfica é possível perceber que todas as curvas apresentam uma queda rápida na perda nas primeiras épocas. Contudo, o banco de dados B2 tende a aumentar o valor da perda, indicando que pode estar sofrendo com *overfitting* ou instabilidade. Já B1 obteve o melhor desempenho entre os três modelos, apresentando a melhor convergência. Por último, B3 apresentou um desempenho novamente intermediário e com menos instabilidade nas últimas épocas.

Assim, para efeito de comparação, os três bancos de dados foram testados em um único banco de dados de teste contendo 800 imagens.

5.2.1. Comparação dos modelos no banco de dados de teste

Uma importante maneira de avaliar o desempenho de modelos é através da matriz de confusão. As matrizes dos modelos treinados e validados no banco de dados de validação de B3 podem ser vistas abaixo, nas Figuras 29, 30 e 31.

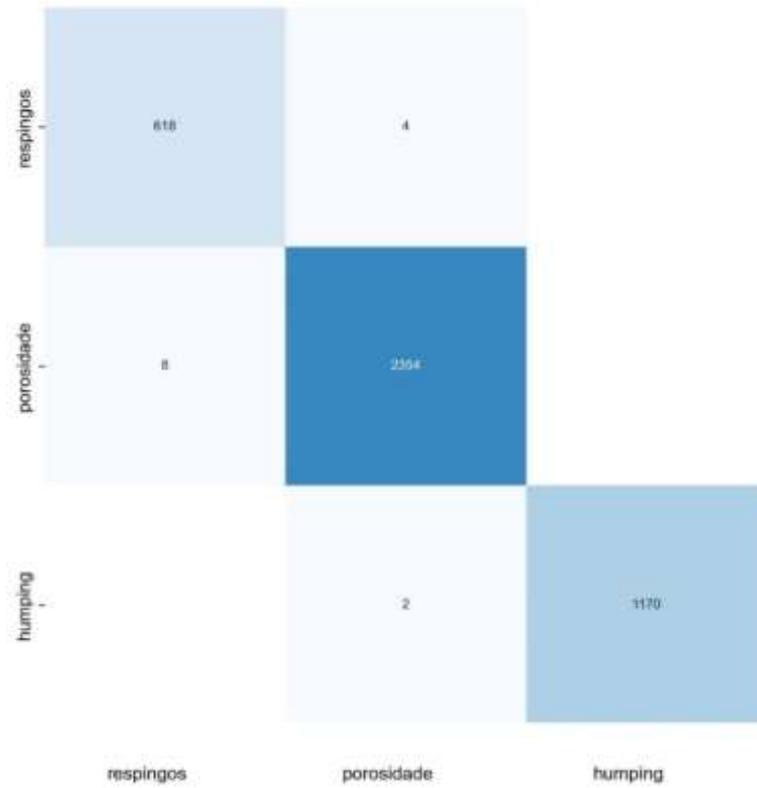


Figura 29: Matriz de Confusão para B1 (Autoria Própria)

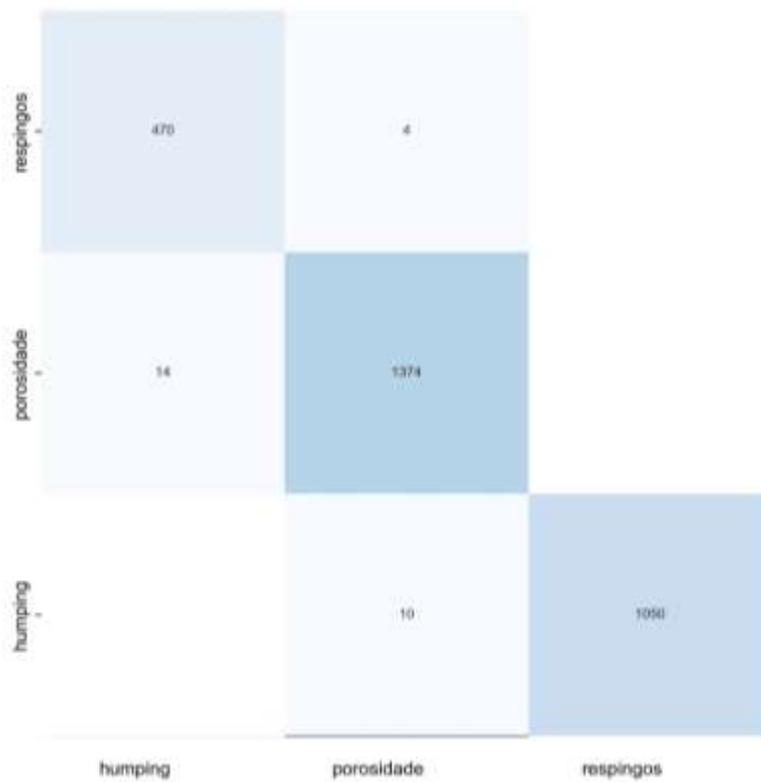


Figura 30: Matriz de confusão para B2 (Autoria Própria)

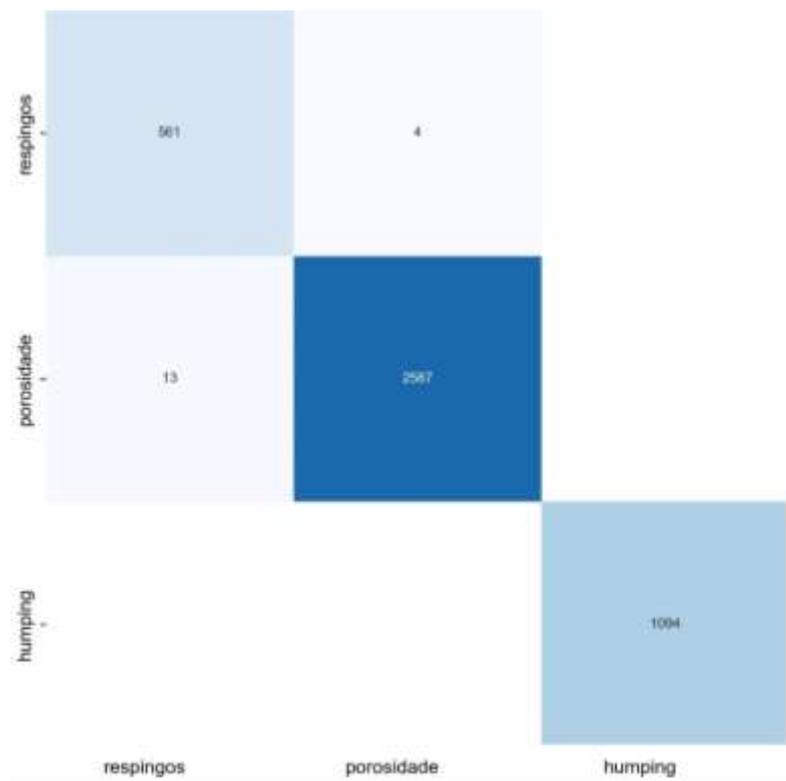


Figura 31: Matriz de confusão para B3 (Autoria própria)

Através da análise das matrizes, é possível observar que a classe Porosidade obteve uma melhora no banco de dados B3. Isso é devido a esse banco de dados possuir uma maior quantidade de imagens com esse defeito. Como o objetivo inicial de B3 era aumentar a precisão e recall dessa classe, pode-se perceber que o aumento do banco de dados nessa classe foi positivo para melhoria na detecção e classificação, em relação a B1 e B2. Em relação a classe *humping*, o banco com melhor desempenho de verdadeiros positivos foi o B1. Como essa classe não passou por mais aumentos de dados nem em B2 nem em B3, pois suas métricas se apresentavam aceitáveis, como pode ser corroborado pelas tabelas 6, 7 e 8, a diminuição dos VP's em B3, Figura 31, não afetou a qualidade total de detecção dessa classe, pois suas métricas gerais ainda ficaram acima de 90%. Já para a classe respingos, B1 obteve melhor desempenho nos testes, obtendo 618 detecções positivas, mostrando que essa classe foi melhor para B1. Abaixo é possível observar a progressão das métricas Precisão, recall e mAP50.

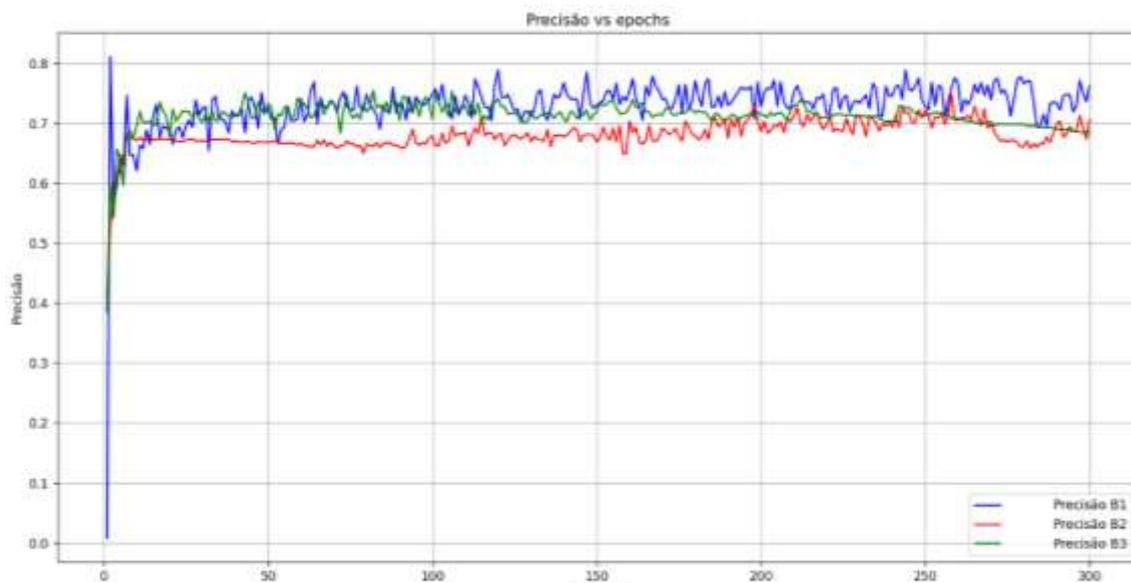


Figura 32: Comparação das precisões dos modelos (Autoria Própria)

Pode ser visto na Figura 32 que, nas primeiras épocas, há um rápido aumento na precisão, indicando uma fase inicial de aprendizado intenso por parte dos modelos. Após aproximadamente 20 a 30 épocas, os três modelos começam a apresentar estabilização nos valores de precisão, o que sugere que a fase de convergência está sendo alcançada. Mesmo com maior taxa de oscilação, o modelo B1 apresenta as maiores taxas de precisão ao longo da maior parte do treinamento. Já B2, mesmo com menos variação ao decorrer das épocas, apresenta uma menor precisão. O modelo B3 apresenta-se com a menor instabilidade entre os três modelos, principalmente ao final das épocas, porém, com um valor de precisão intermediário.

Já para a métrica de *Recall*, Figura 33, observa-se que, nas primeiras épocas, todas as curvas apresentam um crescimento acentuado, caracterizando a fase de aprendizado inicial dos modelos. O modelo B1 mantém os maiores valores médios de *recall* durante a progressão das épocas, com valores variando geralmente entre 0.67 e 0.72, o que mostra que esse modelo apresenta uma maior capacidade de identificação dos VPs, ou seja, de identificar os possíveis defeitos existentes. Os modelos B2 e B3 apresentam desempenhos semelhantes: B2 tendo um desempenho inferior, estabilizando-se em 0.61, e com maior taxa de variação, e B3 apresentando menor taxa de variação e com desempenho próximo de 0.63. inferior, estabilizando-

se em 0.61, e com maior taxa de variação, e B3 apresentando menor taxa de variação e com desempenho próximo de 0.63.

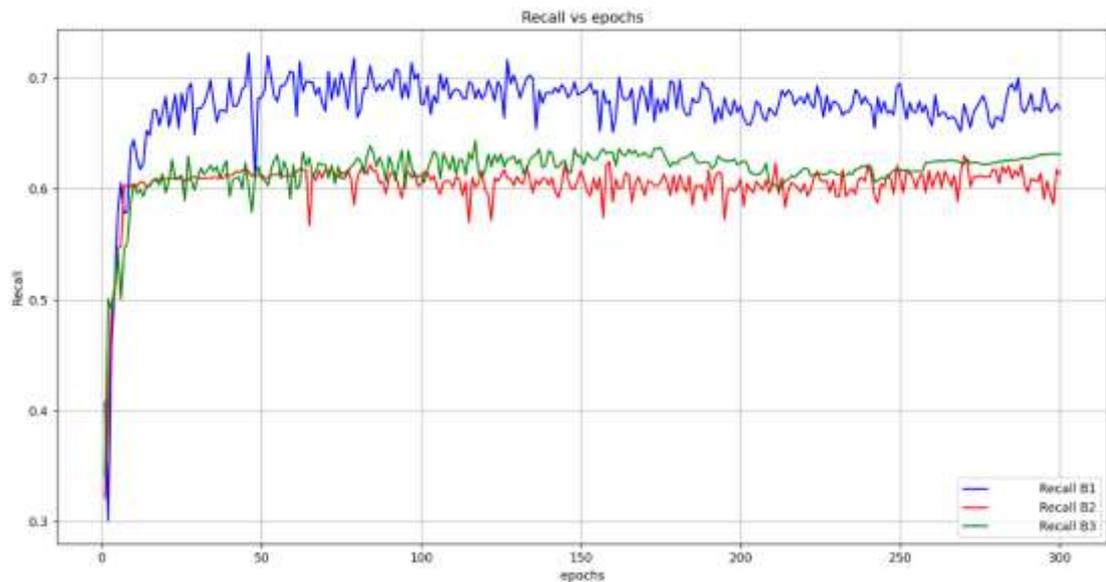


Figura 33: Comparação dos Recalls dos modelos (Autoria Própria)

Para o mAP, Figura 34, B1 também apresentou melhor desempenho global, com valores variando entre aproximadamente 0.70 e 0.73, indicando que é o mais eficaz na localização dos defeitos, considerando uma sobreposição de 50%. Já o modelo B2 apresenta o pior desempenho, estabilizando em torno de 0.61, com pouca variação ao longo das épocas. B3 se apresenta com um desempenho intermediário, com valores de mAP@50 por volta de 0.64, superando o B2 de maneira consistente, mas sem alcançar a performance do B1.

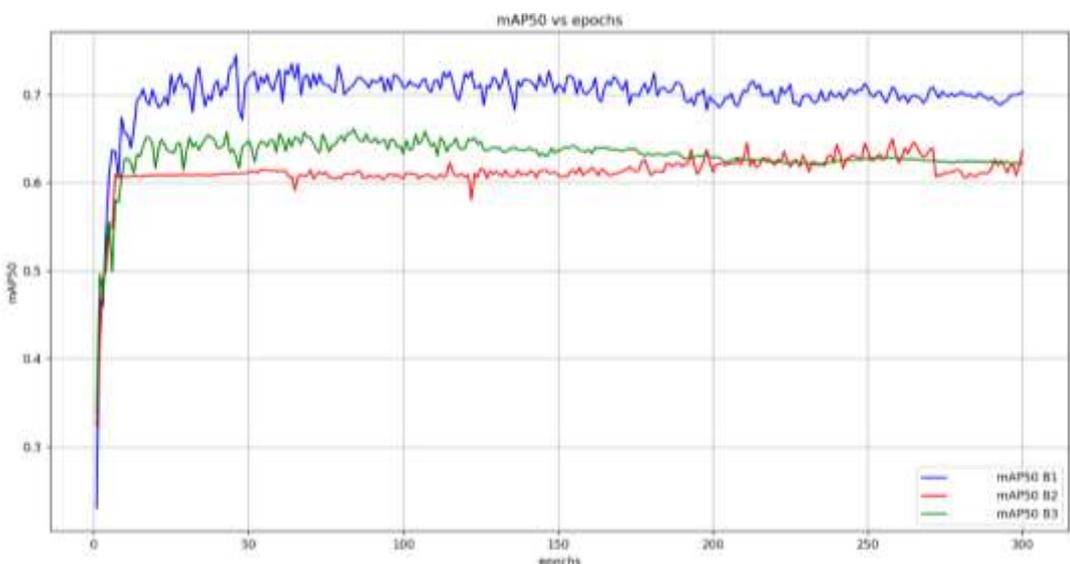


Figura 34: Comparação dos mAPs dos modelos (Autoria Própria)

A métrica F1 está apresentada na Figura 35. O eixo (x) representa a confiança do modelo na detecção, ou seja, o quão correto o modelo está em suas detecções, sendo 0 nenhuma confiança e 1 uma confiança máxima. Já para o eixo (y), está representado o valor F1 score, que é a média harmônica entre precisão e recall. A curva azul escuro, que combina todas as classes, é uma média global de desempenho, as demais curvas representam os valores das classes separadas. Assim, B1 tem o melhor desempenho geral, alcançando um F1 de 0.74 para todas as classes, o que o torna o melhor modelo entre os três. Ele mantém uma boa precisão mesmo com confiança mais baixa, o que é um indicativo de boa generalização. B3 se sai bem em termos de F1, obtendo um valor de 0.67 para uma confiança de 0.273, ficando assim com um desempenho intermediário entre os modelos. Já para B2, o modelo tem o pior desempenho geral, obtendo um valor de F1 de 0.63 para um valor de confiança de 0.209.

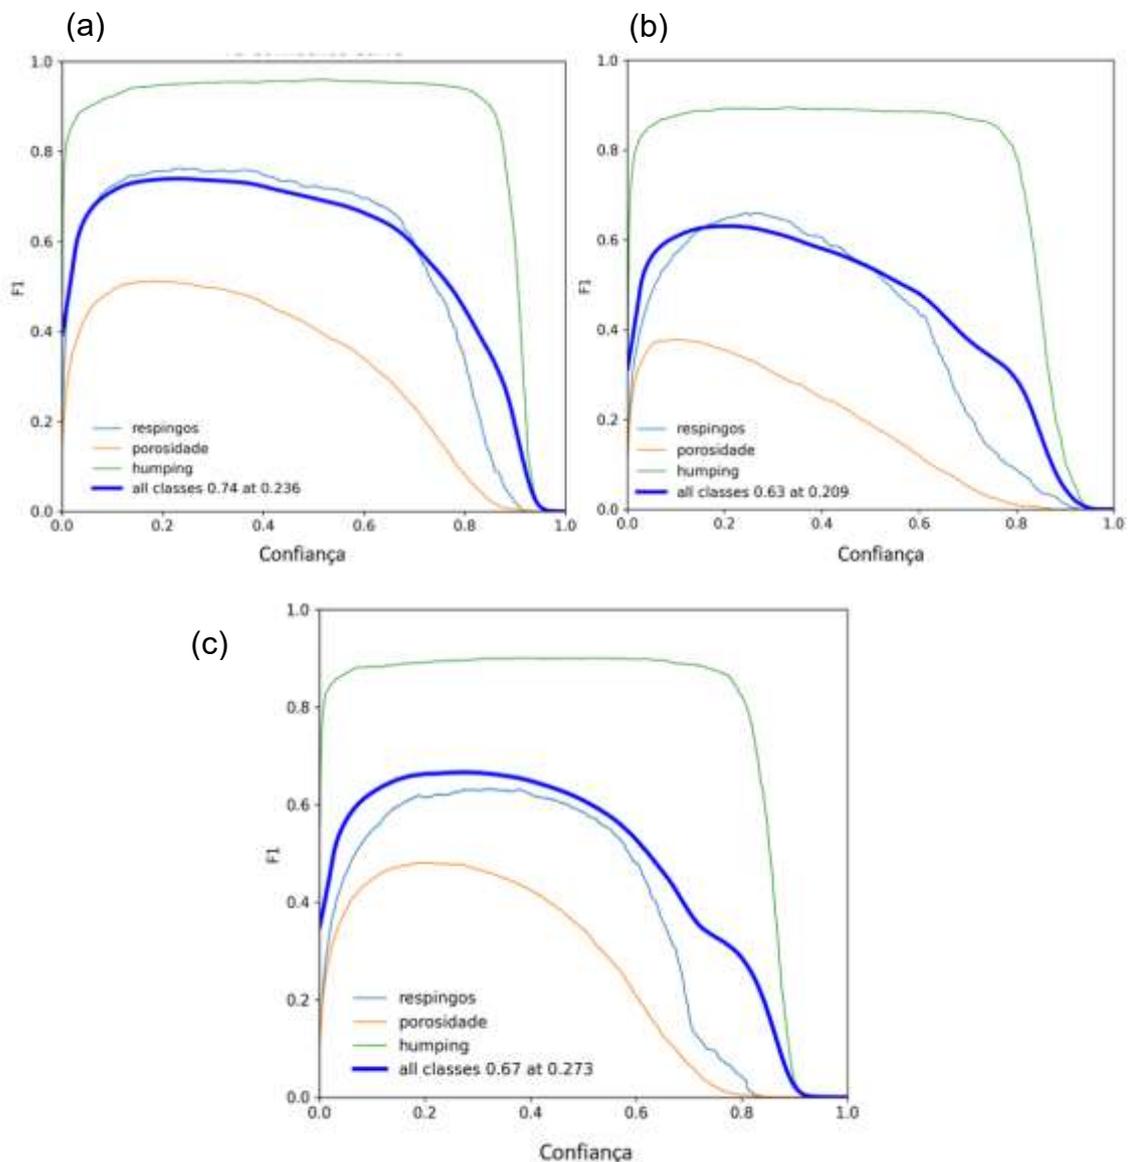


Figura 35: Métrica F1 para B1 (a), B2 (b) e B3 (c)

Conforme mencionado no início da secção 5.3, para detecções de defeitos, é interessante que se tenha um *recall* mais alto, mesmo que sua precisão seja um pouco afetada. No caso dos modelos treinados, o banco de dados com o maior *recall* total foi B1, apresentando um valor de 71,5 % para o modelo, conforme mostrado na Tabela 9.

Tabela 9: Métricas para os melhores pesos de cada modelo

		Precisão	Recall	mAP
Respingos	B1	76,3	75,9	79,8
	B2	71,7	58,9	64,6
	B3	72	55,4	62,5
Porosidade	B1	69,2	40,2	46,6
	B2	61,8	24,8	31,7
	B3	61,7	40,6	43,3
Humping	B1	91,9	98,3	98,5
	B2	89,8	88,8	91,1
	B3	89,8	89,3	91,4
TOTAL	B1	79,1	71,5	75
	B2	74,4	57,5	62,5
	B3	74,5	61,2	65,7

Como pode ser visto, mesmo B3 tendo um maior número de VP's para o defeito de porosidade, sua precisão e seu *recall* foram inferiores a B1. Isso é devido ao cálculo de tais métricas, visto que, conforme equação (1) e (2), os valores dessas métricas dependem também de outros elementos da matriz de confusão, FP e FN. Assim, B3 tem uma maior sensibilidade para detectar possíveis objetos que sejam poros. Todavia, está cometendo mais erros falsos positivos, ou não identificando corretamente esses defeitos.

Por conseguinte, B1, mesmo com menos VP's, tem um melhor equilíbrio entre TP e os outros elementos da matriz de confusão, especialmente FP e FN, resultando em uma maior precisão e *recall*. Assim, os valores de mAP, equação (3), também reforçam a ideia de que o modelo B1 possui uma melhor capacidade geral de detectar e classificar objetos com maior precisão e consistência, mesmo que o modelo B3 registre um número maior de Verdadeiros Positivos. Para os demais defeitos, respingos e *humping*, B1 obteve maior quantidade de VP's, mostrando que a adaptação dos pesos do modelo para essas classes foi melhor. Assim, B1 apresentou

melhor desempenho nas métricas totais, sendo 74.5%, 61.2%, 65,7% e 0.74 respectivamente para Precisão, *Recall*, mAP e F1 score. Demonstrando que, apesar de seu menor número de imagens no conjunto de treinamento, ele é mais eficaz e consistente em detecções e classificações de detecções.

6. CONCLUSÕES

A qualidade das imagens empregadas no treinamento da rede neural, através do YOLO V8, tem um impacto direto nos resultados obtidos. Inicialmente, foi desenvolvido um protótipo de sistema voltado ao reconhecimento automático de falhas, integrando tecnologias de aprendizado de máquina aplicadas a imagens capturadas durante o processo de fabricação. A criação e ampliação de um banco de dados de defeitos superficiais foi uma etapa crítica, exigindo atenção especial, dada a influência direta da qualidade e da quantidade de imagens nos resultados do modelo de detecção. Além disso, a quantidade de fotos no banco de dados influencia no resultado do aprendizado da rede neural, por isso, a etapa de aumento artificial de dados também tem uma importância fundamental.

A aplicação do algoritmo baseado em Rede Neural Convolutiva, utilizando especificamente o YOLOv8, possibilitou a detecção e classificação de diferentes tipos de defeitos, com destaque para a boa performance na identificação de *humping*, ultrapassando os 90% nas métricas, e os desafios enfrentados com a porosidade, que ainda demanda refinamento do banco de dados e melhorias nos métodos de treinamento, pois resultou em um baixo *recall*, menor que 50% em todos os bancos treinados. Dentre os modelos testados, o modelo B1 demonstrou maior eficácia, revelando que, mesmo com menor volume de dados, a qualidade e consistência das imagens impactam mais que a quantidade isoladamente.

O modelo B1 alcançou os maiores valores das métricas utilizadas, indicando maior eficácia e consistência nas detecções, mesmo com um conjunto de treinamento menor. Por outro lado, o modelo B3, apesar de ter um banco de dados maior, não apresentou melhor desempenho, ficando com valores intermediários das métricas. Isso pode ter ocorrido devido à introdução de ruído ou à maior diversidade de imagens, que dificultaram a generalização e a especialização do modelo.

Além disso, com a criação de uma IHM, permitiu-se a visualização prática e interativa dos resultados, favorecendo a aplicabilidade da solução tanto em contextos industriais quanto acadêmicos. Dessa maneira, esta ferramenta contribui com uma ferramenta robusta e adaptável, oferecendo suporte à detecção precoce de falhas e abrindo caminhos para novos estudos e aplicações em sistemas inteligentes de visão computacional.

Assim, as principais contribuições deste trabalho incluem a identificação de regiões com defeitos em imagens, permitindo a detecção precoce de falhas em peças fabricadas e evitando falhas catastróficas; a aplicação de algoritmos robustos com modelos realistas e passíveis de aprimoramento; a possibilidade de otimização dos experimentos e uso da IHM para outros tipos de identificação com treinamento baseado em YOLO; e a criação de um banco de dados de imagens de defeitos superficiais disponibilizado para a comunidade acadêmica.

7. TRABALHOS FUTUROS

- Melhorias no modelo criado e na IHM: Estudo e análise para aprimoramento do modelo desenvolvido com a detecção de mais defeitos, além de aperfeiçoamento da Interface Homem-Máquina (IHM).
- Incremento dos dados e métricas: Realização de experimentos para aumentar a base de dados, além da Melhoria das métricas de desempenho, principalmente a de porosidade.
- Implementação da técnica SAHI (Slicing Aided Hyper Inference): Tal técnica pode melhorar a detecção de objetos em imagens ao passo que dividindo uma imagem em partes menores e executando o algoritmo de detecção em cada parte, com o objetivo de melhorar a detecção e rastreamento de objetos em aplicações em tempo real. Tal técnica foi adicionada na versão 11 do YOLO, lançada ao final de 2024, e pode melhorar a detecção do defeito de porosidade, por exemplo.

8. REFERÊNCIAS

A. ISO. EM ISO 13916: 2017 Guidance on the measurement of preheating temperature, in terpass temperature and preheat maintenance temperature. **ISO 13916:2017(E)**, v. 2, p. 4, 2017.

ADEBAYO, A.; MEHNEN, J.; TONNELIER, X. Limiting travel speed in additive layer manufacturing. 2012.

ARAÚJO, A. M. **DETECÇÃO E DESTAQUE EM VÍDEO DE OBJETOS UTILIZANDO YOLO**. [s.l.] Universidade Federal da Paraíba, 2022.

BLOCK, S. A. B. **INSPEÇÃO E CLASSIFICAÇÃO DE PICOS EM PEÇAS ESTAMPADAS DE METAL UTILIZANDO REDE NEURAL CONVOLUCIONAL**. [s.l.] Universidade Tecnológica Federal do Paraná, 2018.

BOTTON, T. **ESTUDO COMPARATIVO DA RESISTÊNCIA À CORROSÃO EM MEIO ÁCIDO E EM MEIO CONTENDO CLORETO DOS AÇOS INOXIDÁVEIS UNS S44400, UNS S30403 e UNS S31603, OBTIDOS POR LAMINAÇÃO A QUENTE**. [s.l.] Escola Politécnica da Universidade de São Paulo, 2008.

BUSACHI, A. et al. Designing a WAAM Based Manufacturing System for Defence Applications. **Procedia CIRP**, v. 37, p. 48–53, 2015.

CABELLO, F. et al. **Implementation of a fixed-point 2D Gaussian Filter for Image Processing based on FPGA**. 2015 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA). **Anais...IEEE**, 2015.

CHEN, L. et al. Rapid surface defect identification for additive manufacturing with in-situ point cloud processing and machine learning. **Virtual and Physical Prototyping**, v. 16, n. 1, p. 50–67, 2021.

CHEN, X. et al. Effect of heat treatment on microstructure, mechanical and corrosion properties of austenitic stainless steel 316L using arc additive manufacturing. **Materials Science and Engineering: A**, v. 715, p. 307–314, 2018.

COELHO, F. G. F. **DESENVOLVIMENTO DE UM SISTEMA DE VISÃO DE BAIXO CUSTO UTILIZANDO UM MANIPULADOR ROBÓTICO INDUSTRIAL VISANDO A AUTOMATIZAÇÃO DE PROCESSO DE SOLDAGEM**. [s.l.] Universidade Federal de Minas Gerais, 2016.

COELHO, F. G. F. **DESENVOLVIMENTO DE UM SISTEMA BASEADO EM AQUISIÇÃO DE IMAGENS PARA A PARAMETRIZAÇÃO DO PROCESSO GMAW-P EM MANUFATURA ADITIVA**. [s.l.] Universidade Federal de Minas Gerais, 2021.

COLEGROVE, P. A. et al. Microstructure and residual stress improvement in wire and arc additively manufactured parts through high-pressure rolling. **Journal of Materials Processing Technology**, v. 213, n. 10, p. 1782–1791, 2013.

CUNNINGHAM, C. R. et al. Invited review article: Strategies and processes for high quality wire arc additive manufacturing. **Additive Manufacturing**, v. 22, p. 672–686, 2018.

DASS, A.; MORIDI, A. State of the Art in Directed Energy Deposition: From Additive Manufacturing to Materials Design. **Coatings**, v. 9, n. 7, 2019.

DEBROY, T. et al. Additive manufacturing of metallic components – Process, structure and properties. **Progress in Materials Science**, v. 92, p. 112–224, 2018.

DEMIR, A. G. Micro laser metal wire deposition for additive manufacturing of thin-walled structures. **Optics and Lasers in Engineering**, v. 100, p. 9–17, 2018.

DING, D. et al. Wire-feed additive manufacturing of metal components: technologies, developments and future interests. **International Journal of Advanced Manufacturing Technology**, v. 81, n. 1–4, p. 465–481, 2015.

DING, J. et al. Thermo-mechanical analysis of Wire and Arc Additive Layer Manufacturing process on large multi-layer parts. **Computational Materials Science**, v. 50, n. 12, p. 3315–3322, 2011.

FADAEI, M.; BISAZZA, A.; MONZ, C. Data augmentation for low-resource neural machine translation. **arXiv preprint arXiv:1705.00440**, 2017.

FELZENSZWALB, P. F. et al. Object Detection with Discriminatively Trained Part-Based Models. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 32, n. 9, p. 1627–1645, 2010.

FERRANTE, G. S. et al. **Understanding the state of the Art in Animal detection and classification using computer vision technologies**. 2021 IEEE International Conference on Big Data (Big Data). **Anais...2021**.

FERRANTE, G. S. **Detecção de animais com risco de extinção utilizando arquiteturas You Only Look Once (YOLO) para rodovias inteligentes com suporte a computação de borda**. Dissertação—[s.l.] Universidade de São Paulo, 2023.

FERRARESI, H. N. **Efeito dos ciclos térmicos da manufatura aditiva por soldagem a arco sobre a dureza e microestrutura da zac de um ferro fundido nodular**. [s.l.] Universidade Federal de Uberlândia, 2018.

HADI, Z. et al. **Implementation of image enhancement techniques based on intel edison platform**. 2016 1st International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE). **Anais...**2016.

HAMRANI, A. et al. Applying machine learning to wire arc additive manufacturing: a systematic data-driven literature review. **Journal of Intelligent Manufacturing**, p. 1–33, 2023.

HE, X. et al. Automatic defects detection and classification of low carbon steel WAAM products using improved remanence/magneto-optical imaging and cost-sensitive convolutional neural network. **Measurement: Journal of the International Measurement Confederation**, v. 173, 2021.

HU, Z. et al. Welding parameters prediction for arbitrary layer height in robotic wire and arc additive manufacturing. **Journal of Mechanical Science and Technology**, v. 34, p. 1683–1695, 2020.

HUANG, C. et al. Rapid surface defects detection in wire and arc additive manufacturing based on laser profilometer. **Measurement: Journal of the International Measurement Confederation**, v. 189, 2022.

HUANG, S. H. et al. Additive manufacturing and its societal impact: a literature review. **The International journal of advanced manufacturing technology**, v. 67, p. 1191–1203, 2013.

ISO, A. ISO/ASTM 52900: 2015 additive manufacturing—general principles—terminology. **ASTM F2792-10e1**, v. 1, p. 1–19, 2015.

JAFARI, D.; VANEKER, T. H. J.; GIBSON, I. Wire and arc additive manufacturing: Opportunities and challenges to control the quality and accuracy of manufactured parts. **Materials and Design**, v. 202, 2021.

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, n. 3, p. 685–695, 2021.

KEGLEVICH, G.; ANDRIJAUSKAS, F. TÉCNICAS DE MELHORIA DE IMAGENS PARA O REALCE DE TUMORES CEREBRAIS EM IMAGENS DE RESSONANCIA MAGNÉTICA. **Revista Ensaios Pioneiros**, v. 8, n. 1, 2024.

KHOSLA, C.; SAINI, B. S. **Enhancing Performance of Deep Learning Models with different Data Augmentation Techniques: A Survey**. 2020 International Conference on Intelligent Engineering and Management (ICIEM). **Anais...**2020.

KOZAMERNIK, N.; BRAČUN, D.; KLOBČAR, D. WAAM system with interpass temperature control and forced cooling for near-net-shape printing of small metal

components. **The International Journal of Advanced Manufacturing Technology**, v. 110, n. 7, p. 1955–1968, 2020.

KUMAR, P.; JAIN, N. K. Surface roughness prediction in micro-plasma transferred arc metal additive manufacturing process using K-nearest neighbors algorithm. **The International Journal of Advanced Manufacturing Technology**, v. 119, n. 5–6, p. 2985–2997, 2022.

LASI, H. et al. Industry 4.0. **Business & information systems engineering**, v. 6, p. 239–242, 2014.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015.

LI, W. et al. Deep learning based online metallic surface defect detection method for wire and arc additive manufacturing. **Robotics and Computer-Integrated Manufacturing**, v. 80, 2023.

LI, Y. Deep reinforcement learning: An overview. **arXiv preprint arXiv:1701.07274**, 2017.

LI, Y. et al. Towards intelligent monitoring system in wire arc additive manufacturing: a surface anomaly detector on a small dataset. **International Journal of Advanced Manufacturing Technology**, v. 120, n. 7–8, p. 5225–5242, 2022.

LI, Y.; SU, C.; ZHU, J. Comprehensive review of wire arc additive manufacturing: Hardware system, physical process, monitoring, property characterization, application and future prospects. **Results in Engineering**, v. 13, p. 100330, 2022.

LIU, J. et al. Wire and arc additive manufacturing of metal components: a review of recent research developments. **The International Journal of Advanced Manufacturing Technology**, v. 111, p. 149–198, 2020.

LO, K. H.; SHEK, C. H.; LAI, J. K. L. Recent developments in stainless steels. **Materials Science and Engineering: R: Reports**, v. 65, n. 4, p. 39–104, 2009.

MADHAVADAS, V. et al. **A review on metal additive manufacturing for intricately shaped aerospace components. CIRP J Manuf Sci Technol**, 39: 18–36. , 2022.

MAHARANA, K.; MONDAL, S.; NEMADE, B. A review: Data pre-processing and data augmentation techniques. **Global Transitions Proceedings**, v. 3, n. 1, p. 91–99, 2022.

MANAIA, J. P.; CEREJO, F.; DUARTE, J. Revolutionising textile manufacturing: a comprehensive review on 3D and 4D printing technologies. **Fashion and Textiles**, v. 10, n. 1, p. 20, 2023.

MENESES, V. A. DE. **Efeito da estabilidade da transferência metálica (respingos) na soldagem MIG/MAG por curto-circuito sobre a geração de fumos e gases.** [s.l.] Universidade Federal de Uberlândia, 2013.

MEZA, G. et al. **Control of a three-axis CNC machine using PLC S7 1200 with the Mach3 software adapted to a Modbus TCP/IP network.** 2018 IEEE XXV International Conference on Electronics, Electrical Engineering and Computing (INTERCON). **Anais...**2018.

MILEWSKI, J. O.; MILEWSKI, J. O. **Additive manufacturing metal, the art of the possible.** [s.l.] Springer, 2017.

NOMOTO, S. et al. Multi-Phase Field Method for Solidification Microstructure Evolution for a Ni-Based Alloy in Wire Arc Additive Manufacturing. **Metals**, v. 12, n. 10, p. 1720, 2022.

PALMEIRA BELOTTI, L. et al. Microstructural characterisation of thick-walled wire arc additively manufactured stainless steel. **Journal of Materials Processing Technology**, v. 299, p. 117373, 2022.

QAMAR, R.; ZARDARI, B. A. Artificial neural networks: An overview. **Mesopotamian Journal of Computer Science**, v. 2023, p. 124–133, 2023.

REDMON, J. et al. **You only look once: Unified, real-time object detection.** Proceedings of the IEEE conference on computer vision and pattern recognition. **Anais...**2016.

SAMES, W. J. et al. The metallurgy and processing science of metal additive manufacturing. **International Materials Reviews**, v. 61, n. 5, p. 315–360, 3 jul. 2016.

SHEIKH, H.; PRINS, C.; SCHRIJVERS, E. Artificial Intelligence: Definition and Background BT - Mission AI: The New System Technology. Em: SHEIKH, H.; PRINS, C.; SCHRIJVERS, E. (Eds.). Cham: Springer International Publishing, 2023. p. 15–41.

SHINDE, P. P.; SHAH, S. **A Review of Machine Learning and Deep Learning Applications.** 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA). **Anais...**2018.

SILVA, B. H. S. Avaliação e aplicabilidade de arame ultrafino em Manufatura Aditiva por Deposição a Arco (MADA). 2020.

SO, M. S. et al. Prediction of Metal Additively Manufactured Surface Roughness Using Deep Neural Network. **Sensors**, v. 22, n. 20, 2022.

SOUZA, D. et al. Influência da tensão de soldagem e do gás de proteção sobre a correlação entre indutância e regularidade da transferência metálica na soldagem MIG/MAG por curto-circuito. **Soldagem & Inspeção**, v. 16, p. 114–123, 2011.

SOUZA, L. B. O. DE. **CORRELAÇÃO ENTRE PROCESSOS DE FABRICAÇÃO CONVENCIONAL E POR MANUFATURA ADITIVA COM AS PROPRIEDADES DO AÇO INOXIDÁVEL 316L**. [s.l.] Universidade Federal de Uberlândia, 2022.

SPOERK, M.; HOLZER, C.; GONZALEZ-GUTIERREZ, J. Material extrusion-based additive manufacturing of polypropylene: A review on how to improve dimensional inaccuracy and warpage. **Journal of Applied Polymer Science**, v. 137, n. 12, p. 48545, 2020.

SUN, C. et al. Additive manufacturing for energy: A review. **Applied Energy**, v. 282, p. 116041, 2021.

TEIXEIRA, F. R. et al. Combined effect of the interlayer temperature with travel speed on features of thin wall WAAM under two cooling approaches. **The International Journal of Advanced Manufacturing Technology**, v. 126, n. 1–2, p. 273–289, 2023.

TERVEN, J.; CÓRDOVA-ESPARZA, D.-M.; ROMERO-GONZÁLEZ, J.-A. **A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS**. **Machine Learning and Knowledge Extraction**, 2023.

TESHALE, A. B. et al. A Systematic Review of Artificial Intelligence Models for Time-to-Event Outcome Applied in Cardiovascular Disease Risk Prediction. **Journal of Medical Systems**, v. 48, n. 1, p. 68, 2024.

THOMAS-SEALE, L. E. J. et al. The barriers to the progression of additive manufacture: Perspectives from UK industry. **International Journal of Production Economics**, v. 198, p. 104–118, 2018.

TOWNSEND, A. et al. Surface texture metrology for metal additive manufacturing: a review. **Precision Engineering**, v. 46, p. 34–47, 2016.

TÜMER, M.; YILMAZ, R. Characterization of microstructure, chemical composition, and toughness of a multipass welded joint of austenitic stainless steel AISI316L. **International Journal of Advanced Manufacturing Technology**, v. 87, n. 9–12, p. 2567–2579, 2016.

VAFADAR, A. et al. Advances in metal additive manufacturing: a review of common processes, industrial applications, and current challenges. **Applied Sciences**, v. 11, n. 3, p. 1213, 2021.

VAN ENGELEN, J. E.; HOOS, H. H. A survey on semi-supervised learning. **Machine Learning**, v. 109, n. 2, p. 373–440, 2020.

WHEAT, E. et al. Sinter structure analysis of titanium structures fabricated via binder jetting additive manufacturing. **Materials & Design**, v. 156, p. 167–183, 2018.

WILLIAMS, S.; MARTINA, F. Wire+ arc additive manufacturing vs. traditional machining from solid: a cost comparison. **Mater Sci Technol (UK)**, v. 32, n. 1, p. 27, 2015.

WU, B. et al. A review of the wire arc additive manufacturing of metals: properties, defects and quality improvement. **Journal of Manufacturing Processes**, v. 35, p. 127–139, 2018a.

WU, B. et al. Effects of heat accumulation on microstructure and mechanical properties of Ti6Al4V alloy deposited by wire arc additive manufacturing. **Additive Manufacturing**, v. 23, p. 151–160, 2018b.

WU, D. et al. Understanding of humping formation and suppression mechanisms using the numerical simulation. **International Journal of Heat and Mass Transfer**, v. 104, p. 634–643, 2017.

WU, J. et al. An in situ surface defect detection method based on improved you only look once algorithm for wire and arc additive manufacturing. **Rapid Prototyping Journal**, v. 29, n. 5, p. 910–920, 2023.

XIONG, J. et al. Influences of process parameters on surface roughness of multi-layer single-pass thin-walled parts in GMAW-based additive manufacturing. **Journal of Materials Processing Technology**, v. 252, p. 128–136, 2018.

YUAN, L. et al. Investigation of humping phenomenon for the multi-directional robotic wire and arc additive manufacturing. **Robotics and Computer-Integrated Manufacturing**, v. 63, p. 101916, 2020.

ZAHIDIN, M. R. et al. Research challenges, quality control and monitoring strategy for Wire Arc Additive Manufacturing. **Journal of Materials Research and Technology**, v. 24, p. 2769–2794, 2023.

ZHANG, J. et al. 3D reconstruction for motion blurred images using deep learning-based intelligent systems. **Computers, Materials & Continua**, v. 66, n. 2, p. 2087–2104, 2021.

ZHANG, L.; WANG, S.; LIU, B. Deep learning for sentiment analysis: A survey. **WIRES Data Mining and Knowledge Discovery**, v. 8, n. 4, p. e1253, 1 jul. 2018.

ZHANG, W. et al. Application of machine learning, deep learning and optimization algorithms in geoenvironment and geoscience: Comprehensive review and future challenge. **Gondwana Research**, v. 109, p. 1–17, 2022.

ZHANG, Z. et al. Surface quality and forming characteristics of thin-wall aluminium alloy parts manufactured by laser assisted MIG arc additive manufacturing. **International Journal of Lightweight Materials and Manufacture**, v. 1, n. 2, p. 89–95, 2018.

ZHAO, Z.-Q. et al. Object detection with deep learning: A review. **IEEE transactions on neural networks and learning systems**, v. 30, n. 11, p. 3212–3232, 2019.