

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Leonardo Kenny Treichel da Cunha

**Sistema de aquisição de dados e detecção de
falhas para impressoras 3D utilizando modelos
inteligentes**

Porto Alegre

2024

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Leonardo Kenny Treichel da Cunha

**Sistema de aquisição de dados e detecção de falhas para
impressoras 3D utilizando modelos inteligentes**

Projeto de Diplomação II, apresentado ao Departamento de Engenharia Elétrica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Engenheiro Eletricista

UFRGS

Orientador: Prof. Dr. Tiago Oliveira Weber

Porto Alegre

2024

Leonardo Kenny Treichel da Cunha

Sistema de aquisição de dados e detecção de falhas para impressoras 3D utilizando modelos inteligentes

Projeto de Diplomação II, apresentado ao Departamento de Engenharia Elétrica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Engenheiro Eletricista

BANCA EXAMINADORA

Prof. Dr. Altamiro Amadeu Susin
UFRGS

Prof. Dr. Ivan Müller
UFRGS

Prof. Dr. Tiago Oliveira Weber
Orientador - UFRGS

Aprovado em Dia de Mês de 2024.

Resumo

A popularização das impressoras 3D revolucionou a manufatura, permitindo a personalização e inovação em setores como o industrial, automotivo, médico e farmacêutico. No entanto, essas máquinas, que operam sem sistemas de controle fechado, são propensas a falhas operacionais, especialmente quando manuseadas por usuários inexperientes. Diversas pesquisas têm abordado a detecção de falhas, utilizando diferentes abordagens, com ou sem a integração de novos sensores. Apesar dos avanços, a disponibilidade de dados públicos para a validação e comparação de modelos ainda é escassa. Este trabalho busca preencher essa lacuna ao disponibilizar uma base de dados com seis estados operacionais distintos, permitindo a comparação de modelos de detecção de falhas. Além disso, é proposto um sistema de aquisição de dados que visa facilitar futuros estudos e expandir as bases de dados públicas. Modelos de detecção de falhas utilizando modelos de memória de curto longo prazo (LSTM, Long-Short Term Memory), replicados a partir de um estudo anterior, obtiveram uma acurácia de 70% na identificação de falhas.

Palavras-chave: Detecção de falhas, Impressoras 3D, Sensor de aceleração, LSTM

Abstract

The widespread adoption of 3D printers has revolutionized manufacturing, enabling customization and innovation across sectors such as industrial, automotive, medical, and pharmaceutical. However, these machines, which operate without closed-loop control systems, are prone to operational failures, especially when handled by inexperienced users. Various studies have addressed fault detection using different approaches, with or without the integration of additional sensors. Despite these advances, the availability of public data for validating and comparing models remains limited. This work aims to bridge this gap by providing a dataset with six distinct operational states, facilitating the comparison of fault detection models. Additionally, a data acquisition system is proposed to support future studies and expand public datasets. Fault detection models using LSTMs, replicated from a previous study, achieved 70% accuracy in identifying faults.

Keywords: Fault detection, 3D printers, acceleration sensor, LSTM

Lista de Figuras

Figura 1 – Artigos publicados por ano.	12
Figura 2 – Espectro do Sinal Original.	16
Figura 3 – Espectro do sinal de amostragem com $(\Omega_S) > 2(\Omega_N)$	16
Figura 4 – Espectro do sinal de amostragem com $(\Omega_S) < 2(\Omega_N)$	16
Figura 5 – Dois casos de SNR: um SNR alto e um SNR baixo.	18
Figura 6 – Condições de projeto do filtro passa baixas.	18
Figura 7 – Seleção do hiperplano de projeção das componentes.	22
Figura 8 – Armação principal.	30
Figura 9 – Desenhos da montagem do arco.	31
Figura 10 – Ângulos eixo X.	31
Figura 11 – Eixo X.	32
Figura 12 – Carro da ponte rolante.	32
Figura 13 – Posição de fixação do carro da ponte rolante.	33
Figura 14 – Calibrando extrusora.	34
Figura 15 – Botões rotativos dos tensionadores.	34
Figura 16 – Impressão de torre de temperaturas.	35
Figura 17 – Exemplos de falhas de impressão.	36
Figura 18 – Impressão de torre de retrações.	37
Figura 19 – Exemplos de falhas de impressão.	37
Figura 20 – Peça de fixação do sensor.	38
Figura 21 – Bicos utilizados para impressão das peças durante a geração da base de dados.	40
Figura 22 – Diagrama do sistema de aquisição dos dados.	41
Figura 23 – Diagrama de blocos funcional ADXL345.	41
Figura 24 – Estrutura dos dados.	43
Figura 25 – Fotos de uma <i>bench</i> impressa.	44
Figura 26 – Resultado do filtro Butterworth.	45
Figura 27 – Exemplo dos resultados da subamostragem de 3200 Hz para 200 Hz.	46
Figura 28 – Imagem formada por amostras de uma impressão saudável.	47
Figura 29 – Modelos de detecção de falhas reproduzidos.	48
Figura 30 – Distribuição de amostras por classe.	49
Figura 31 – Fotos dos modelos impressos em cada um dos estados da máquina.	50
Figura 32 – Matriz de confusão dos modelos treinados.	52
Figura 33 – Gráfico da <i>accuracy</i> dos modelos híbridos pelas épocas de treinamento.	53
Figura 34 – Gráfico da <i>accuracy</i> dos modelos clássicos pelas épocas de treinamento.	54

Lista de Tabelas

Tabela 1 – Bibliotecas da aquisição de dados.	27
Tabela 2 – Especificações do Esp32 WROOM-32 utilizado na aquisição.	27
Tabela 3 – Especificações do sensor ADXL345.	27
Tabela 4 – Especificações da Raspberry pi 4	28
Tabela 5 – Especificações para tratamento dos dados e treinamento dos modelos.	28
Tabela 6 – Especificações do computador utilizado.	28
Tabela 7 – Especificações da impressora.	29
Tabela 8 – Características do material de impressão.	29
Tabela 9 – Parametros recomendados para o material de impressão.	30
Tabela 10 – Parâmetros da impressora.	39
Tabela 11 – Especificações das obstruções.	40
Tabela 12 – Quantidades de impressões realizadas por estado da máquina.	49
Tabela 13 – Resultado dos modelos de aprendizado de máquina.	51

Lista de abreviaturas

AM	<i>Additive Manufacturing</i>
ADC	<i>Analog to Digital Converter</i>
ANOVA	Análise de variância
ANN	<i>Artificial Neural Network</i>
CNN	<i>Convolutional Neural Network</i>
FIFO	<i>First Input First Output</i>
FFF	<i>Fused Filament fabrication</i>
FDM	<i>Fused Deposition Modeling</i>
LSB	<i>Least Significant Bit</i>
LSTM	<i>Long short-term memory</i>
MEMS	<i>Micro-Electro-Mechanical Systems</i>
RTOS	<i>Real time operating system</i>
RNN	<i>Recurrent Neural Network</i>
SPC	<i>Statistical process control</i>
SPI	<i>Serial peripheral interface</i>
SVM	<i>Support Vector Machine</i>
TCC	Trabalho de Conclusão de Curso
TL	<i>Transfer Learning</i>

Sumário

1	INTRODUÇÃO	10
1.1	Motivação	10
1.2	Objetivos	11
1.2.1	Objetivo Geral	11
1.2.2	Objetivos Específicos	11
2	REVISÃO BIBLIOGRÁFICA	12
3	FUNDAMENTAÇÃO TEÓRICA	15
3.1	Acelerômetro	15
3.2	Teorema de Nyquist	15
3.3	Relação sinal-ruído	17
3.4	Filtro Butterworth	17
3.5	Aprendizado de Máquina	19
3.5.1	Aprendizado supervisionado	19
3.5.1.1	Redes Neurais	20
3.5.2	Aprendizado não supervisionado	22
3.5.2.1	Análise de componentes principais	22
3.5.3	Aprendizado por reforço	23
3.6	Métricas de avaliação	23
3.6.1	<i>Precision</i>	23
3.6.2	<i>Recall</i>	23
3.6.3	<i>Accuracy</i>	24
3.6.4	Multiclasse	24
3.6.4.1	<i>Precision</i>	24
3.6.4.2	<i>Recall</i>	25
3.6.4.3	<i>Accuracy</i>	25
4	METODOLOGIA	26
4.1	Materiais utilizados	27
4.2	Preparação e ajuste da máquina	28
4.2.1	A impressora	29
4.2.2	O material (Filamento)	29
4.2.3	Alinhamento da armação principal	30
4.2.4	Ponte rolante	31
4.2.5	Carro da ponte rolante	32

4.2.6	Calibração do motor de passo da extrusora	32
4.2.7	Tensionando as correias	33
4.2.8	Calibração de parâmetros de impressão	34
4.2.9	Sensor acelerômetro	37
4.3	Protocolo para indução de falhas	38
4.3.1	Estado saudável	38
4.3.2	Temperaturas de extrusão anômala	39
4.3.3	Bloqueio parcial do bico de extrusão	39
4.3.4	Carro do eixo X folgado	40
4.4	Aquisição dos Dados	40
4.4.1	Sensor	40
4.4.2	Aquisição	42
4.4.3	Armazenamento	43
4.5	Base de dados	43
4.6	Classificação Inteligente	45
4.6.1	Adaptação da base de dados	45
4.6.2	Extração manual de características	46
4.6.3	Extração de características através de imagens	47
4.6.4	Modelos reproduzidos	47
5	RESULTADOS	49
5.1	Base de dados	49
5.2	Reprodução de modelos da literatura	51
6	CONCLUSÕES	55
6.0.1	Trabalhos Futuros	55
	REFERÊNCIAS BIBLIOGRÁFICAS	57

1 Introdução

Manufatura aditiva (AM, do inglês *Additive Manufacturing*) é o termo geral para as tecnologias que unem material sucessivamente para criar objetos da maneira especificada através de modelos 3D. Estas tecnologias são utilizadas atualmente em diversas aplicações no campo da engenharia industrial bem como outras áreas da sociedade como medicina, educação, arquitetura, cartografia, brinquedos e entretenimento. Entre os tipos de AM estão jateamento de aglutinante (do inglês *binder jetting*), deposição de energia direcionada (do inglês, *directed energy deposition*), extrusão de material (do inglês, *material extrusion*), jateamento de materiais (do inglês, *material jetting*), fusão seletiva a laser (do inglês, *powder bed fusion*), laminação de folhas (do inglês, *sheet lamination*) e fotopolimerização de cuba (do inglês, *vat photopolymerization*) (ISO52900... , 2021).

A introdução de máquinas que utilizam da manufatura aditiva para produzir peças tridimensionais à preços acessíveis, conhecidas como impressoras 3D, marcaram o início da era da democratização da manufatura. As impressoras 3D garantem que os usuários possam customizar, inovar e aprimorar uma peça ou modelo existente para se encaixar nas suas necessidades. O escopo das aplicações destas máquinas é tão grade e variado que inclui os setores de equipamentos comerciais e industriais, automotivos, médicos, farmacêuticos entre outros (NIESS; WENDE, 2017).

1.1 Motivação

A impressão 3D é uma tecnologia revolucionária que está transformando diversos setores, desde a manufatura e engenharia até a medicina e arte. No entanto, a ocorrência de falhas durante o processo de impressão é um desafio significativo tanto para profissionais quanto para usuários recreativos, podendo levar ao desgaste e/ou danos na máquina, perda de tempo e materiais, além de custos adicionais de operação. Essas falhas podem resultar de uma variedade de causas, incluindo problemas mecânicos, erros de configuração, condições ambientais desfavoráveis e defeitos nos materiais.

A área de detecção de falhas em máquinas é um ramo já bem estabelecido, com diversas pesquisas voltadas para uma ampla gama de possíveis problemas e as diferentes formas de detectá-los. No campo da literatura em detecção de falhas de máquinas, um assunto de interesse recente são justamente as impressoras 3D. Dentre os trabalhos, diversos métodos e tipos de sensores são utilizados, desde sensores de atitude com análise de valores limites de operação (BAEK, 2024) até complexos modelos inteligentes que detectam anomalias em imagens (CASTILLO; MONROY; AHMAD, 2024),(KIM; LEE; AHN, 2022) e (PETSIUK; PEARCE, 2022).

A escassez de bases de dados abertas construídas especificamente para a detecção de falhas em impressoras 3D ocasiona na falta de elementos comparativos entre diferentes trabalhos (KHUSHEEF; SHAHBAZI; HASHEMI, 2023), (MALAWADE *et al.*, 2021) e (VOYDIE *et al.*, 2023), mesmo para aqueles que utilizam os mesmos sensores, buscando implementar e demonstrar os resultados de seus modelos de detecção, classificação e/ou predição de falhas.

A criação de uma base de dados aberta é crucial para mitigar este problema e fornecerá uma fonte de informações valiosa para a análise e identificação de padrões associados a diferentes tipos de falhas, sendo possível treinar e avaliar modelos inteligentes que possam prever e identificar falhas de forma precisa e eficiente, permitindo uma intervenção proativa e a correção dos problemas antes que eles resultem em falhas completas, desta forma impulsionando a realização de trabalhos na área.

A avaliação desses modelos utilizando bases de dados padronizadas permitirá determinar quais técnicas são mais eficazes para diferentes tipos de falhas e cenários de impressão. Isso não apenas contribui para a melhoria da qualidade e eficiência dos processos de impressão 3D, mas também avança o campo de estudo.

1.2 Objetivos

1.2.1 Objetivo Geral

O presente trabalho busca gerar uma base de dados de detecção de falhas em impressoras 3D durante a operação da máquina a partir de acelerômetros, aberta ao público fornecendo não apenas os dados, mas também uma explicação detalhada dos métodos e protocolos utilizados durante a geração. Dessa forma, o trabalho auxiliará futuros estudos na realização de comparações de resultados, além de buscar padronizar o protocolo de geração dos dados e falhas para possíveis adições e/ou criação de novas bases de dados. Além disso, com a base de dados, será realizada a avaliação de modelos encontrados na literatura.

1.2.2 Objetivos Específicos

- Projetar um sistema de aquisição de dados;
- Desenvolver um protocolo de calibração de impressoras 3D retilíneas;
- Desenvolver um protocolo de simulação de falhas;
- Gerar uma base de dados disponível ao público;
- Testar e analisar a base de dados utilizando modelos da literatura.


2 Revisão Bibliográfica

Para investigar o estado da arte na detecção de falhas em impressoras 3D em tempo real, foi realizada uma pesquisa sistemática na base de dados Scopus, selecionada por sua ampla cobertura e diversidade de materiais acadêmicos. A pesquisa utilizou as palavras-chave “3d AND printer AND (failure OR fault) AND detection” e abrangeu o período de 2009 e 2024, correspondente a todo o intervalo de tempo disponível na base Scopus. Esse processo resultou na identificação de 238 trabalhos.

Após a análise dos títulos e resumos, foram descartados os estudos que não se alinhavam com o objetivo do presente trabalho, restando 140 artigos que passaram para a fase de leitura completa.

Conforme ilustrado na Figura 1, observa-se que o envio de trabalhos sobre detecção de falhas em impressoras 3D está em ascensão, o que indica uma crescente popularidade do assunto no meio acadêmico.

Figura 1 – Artigos publicados por ano.



Fonte: O Autor, 2024.

Entre os métodos utilizados para detecção de falhas em impressoras 3D observados durante a pesquisa, destacam-se os seguintes:

- **Imagens:** Estudos como os de Castillo, Monroy e Ahmad (2024), Lut *et al.* (2023), e Kim, Lee e Ahn (2022) aplicam técnicas de análise visual para identificar padrões e sinais de falhas de impressão. Esses métodos têm como foco a detecção de anomalias diretamente no aspecto visual do objeto impresso;
- **Sensores de Temperatura:** Trabalhos como os de Rachmawati *et al.* (2023) e Voydie *et al.* (2023) utilizam sensores de temperatura para monitorar oscilações térmicas durante o processo de impressão, correlacionando essas variações com possíveis defeitos no produto final;
- **Sensores de Campo Magnético:** Pesquisas realizadas por Li *et al.* (2021a) e Li *et al.* (2021b) investigam o uso de sensores de campo magnético para detecção de falhas, embora esses métodos sejam menos comuns;
- **Sensores de Aceleração:** Estudos como os de Isiani *et al.* (2023), Baek, Kim e Lee (2024), e Bhattacharya *et al.* (2024) exploram o uso de sensores de aceleração para monitorar vibrações durante a impressão, visando identificar padrões de falhas;
- **Sensores de Atitude:** Trabalhos como os de Guo *et al.* (2019) e Long *et al.* (2020) utilizam sensores de atitude para avaliar o estado geral da máquina, muitas vezes combinando dados de múltiplos sensores para melhorar a precisão na detecção e classificação de falhas.

Dada a relevância dos sensores de aceleração para a detecção de falhas em tempo real, o presente trabalho foca especificamente nessa categoria.

O estudo de Isiani *et al.* (2023) realizou uma análise detalhada sobre o posicionamento dos sensores e as principais componentes de frequência capturadas por sensores de aceleração até 1500 Hz. O estudo concluiu que a melhor eficiência na detecção de falhas é obtida com o sensor fixado próximo ao bico de extrusão, com frequências de interesse alcançando até 450 Hz. Logo, frequências de aquisição inferiores a este valor podem resultar na perda de informações críticas, o que pode explicar as conclusões dos trabalhos de Baek, Kim e Lee (2024) e He *et al.* (2018), que observaram pouco ou nenhum impacto dos sensores de aceleração na classificação de falhas, dado que suas medições foram realizadas com frequências de aquisição inferiores a 100 Hz. Por outro lado, artigos como os de Khusheef, Shahbazi e Hashemi (2023) e Chowdhury, Sinha e Das (2023), que utilizaram frequências superiores, reportaram acurácias na detecção de falhas de 99,85% e 99,75%, respectivamente.

Dos artigos analisados, apenas seis (LEE *et al.*, 2020), (CHOWDHURY; SINHA; DAS, 2023), (ISIANI *et al.*, 2023), (FU *et al.*, 2023), (RACHMAWATI *et al.*, 2023), (KHUSHEEF; SHAHBAZI; HASHEMI, 2023) mencionam a disponibilização de suas bases de dados ou o uso de bases de dados abertas. No entanto, durante o desenvolvimento

deste trabalho, apenas as bases de Fu *et al.* (2023), Khusheef, Shahbazi e Hashemi (2023), Rachmawati *et al.* (2023), e Lee *et al.* (2020) estavam disponíveis.

Das bases de dados disponibilizadas, todas foram geradas durante o processo de impressão com o objetivo de detectar falhas em tempo real. Entre essas, duas são bases de imagens, uma de valores de temperatura e outra de dados de vibração e força de extrusão.

3 Fundamentação Teórica

Nesta seção serão discutidos os conhecimentos teóricos que fundamentam as análises realizadas para obtenção de resultados e o experimento em si.

3.1 Acelerômetro

Os acelerômetros são sensores fundamentais no monitoramento de vibrações e movimentos em uma ampla gama de aplicações, incluindo a detecção de falhas em impressoras 3D. Esses dispositivos são capazes de medir a aceleração linear em uma ou mais direções, geralmente expressa em metros por segundo ao quadrado (m/s^2). A partir dessa medida, é possível inferir diversos comportamentos dinâmicos do sistema em estudo, como oscilações, choques e vibrações, que são indicativos de problemas potenciais em máquinas. Um acelerômetro é essencialmente um dispositivo eletromecânico que gera uma saída elétrica proporcional à aceleração a que é submetido. Existem diferentes tipos de acelerômetros, como os piezoelétricos, capacitivos e Sistemas Micro-Eletromecânicos (MEMS, do inglês *Micro-Electro-Mechanical Systems*) (BALBINOT; BRUSAMARELLO, 2019).

No contexto de monitoramento de impressoras 3D, os acelerômetros MEMS são particularmente populares devido ao seu tamanho reduzido, baixo custo e capacidade de medir acelerações em múltiplos eixos, o que é crucial para capturar a complexidade dos movimentos envolvidos no processo de impressão tridimensional.

O acelerômetro MEMS opera com base na variação de capacitância entre um conjunto de microestruturas móveis e fixas quando submetidas a forças inerciais. Essa variação é então convertida em um sinal elétrico, que pode ser processado para fornecer a aceleração nos eixos X, Y e Z. Essa tecnologia é altamente sensível e permite a detecção de pequenas vibrações e movimentos, o que é essencial para garantir a detecção no monitoramento das condições operacionais de uma impressora 3D.

3.2 Teorema de Nyquist


O Teorema de Nyquist define que deve ser obtida uma frequência de amostragem igual ou maior do que duas vezes a frequência máxima do sinal de entrada de um sistema para que possa ser obtida a representação do sinal original no domínio digital. A frequência máxima do sinal é comumente referida como de frequência de Nyquist (Ω_N) e a frequência

na qual a frequência de amostragem (Ω_S) deve ser excedida é chamada de taxa de Nyquist ($2\Omega_N$).

De forma geral, dado um sinal de entrada $X_c(j\Omega)$, conforme a Figura 2, caso a frequência de amostragem (Ω_S) seja maior do que duas vezes a frequência de Nyquist (Ω_N), ou seja, seja maior ou igual a taxa de Nyquist ($2\Omega_N$), obtém-se a recuperação do sinal original, conforme a Figura 3, caso a frequência de amostragem (Ω_S) não seja alta o suficiente, ou seja, menor do que a taxa de Nyquist ($2\Omega_N$), ocorre a sobreposição do espectro, o chamado efeito de *aliasing*, observado na Figura 4.


No último caso, mostrado na Figura 4, as frequências originalmente altas no espectro do sinal aparecem em regiões de mais baixa frequência, o que impossibilita a representação, pois o sinal amostrado aparenta ter frequência diferente do sinal original. Ressalta-se ainda que a aparição deste efeito pode resultar em interpretações equivocadas sobre a dinâmica do sinal mensurando.

Figura 2 – Espectro do Sinal Original.




Fonte: Oppenheim e Schafer (1999).

Figura 3 – Espectro do sinal de amostragem com $(\Omega_S) > 2(\Omega_N)$.



Fonte: Oppenheim e Schafer (1999).

Figura 4 – Espectro do sinal de amostragem com $(\Omega_S) < 2(\Omega_N)$.



Fonte: Oppenheim e Schafer (1999).

O *aliasing* degrada a qualidade de um sinal digitalizado. Os erros de *aliasing* podem ser reduzidos pela filtragem passa-baixa do sinal analógico antes da digitalização (KORSTEN W. OTTHIUS, 2004). A filtragem passa-baixa mencionada é realizada por um filtro anti-*aliasing*, no qual espera-se que o mesmo limite a máxima frequência do sinal à metade da frequência de amostragem para evitar o efeito *aliasing* na conversão analógico-digital, possibilitando uma correta quantização. Entre os possíveis filtros a serem utilizados, os filtros Butterworth, Chebyshev e Bessel são os mais comuns. O tipo de filtro a ser utilizado deve levar em consideração diversos fatores, entre eles a banda de atenuação disponível, atraso de fase e variações de ganho na banda de passagem. A saber: o processo de conversão de um valor analógico para um código é denominado de quantização (FLOYD, 2007).

3.3 Relação sinal-ruído

A presença de ruídos, sejam eles inerentes ou externos ao circuito, faz com que os sinais de saída de qualquer sistema eletrônico sejam modificados, tornando-se diferentes dos sinais originais. A qualidade do sinal é especificada pela razão sinal-ruído (SNR, do inglês *Signal-to-Noise Ratio*) (SIMÕES, 2008).

A presença de ruído degrada a qualidade de um sinal e impõe o limite o tamanho dos sinais que podem ser detectados, medidos e interpretados com sucesso. Quanto mais pobre o SNR, mais difícil é resgatar o sinal útil do ruído (FRANCO, 2015).

SNR é na verdade a relação entre o que é desejado (sinal) e o que não é desejado (ruído). Um SNR alto significa que o sinal está menos corrompido por ruído; um SNR baixo significa que o sinal está mais corrompido pelo ruído (FOROUZAN, 2010). Na Figura 5, nota-se os dois casos.

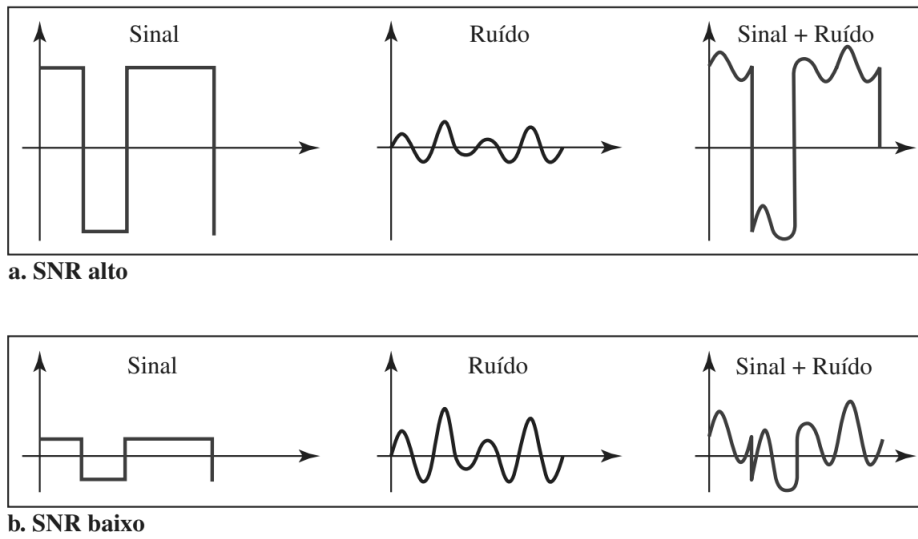
A representação matemática do SNR_{dB} é definido pela equação 1 provida por (FOROUZAN, 2010).

$$SNR = 10 * \log_{10} \frac{X_{signal}^2}{X_{noise}^2} \quad (1)$$

3.4 Filtro Butterworth

O filtro Butterworth é um tipo de filtro analógico ou digital, projetado para ter uma resposta em frequência o mais plana possível na banda passante. Isto significa que ele não apresenta ondulações nessa região, o que torna o filtro ideal em aplicações onde é necessário manter a integridade do sinal original dentro da faixa de frequência de interesse.

Figura 5 – Dois casos de SNR: um SNR alto e um SNR baixo.




Fonte: Forouzan (2010).

A Equação 2 dada por HAYKIN e VEEN (2001), define a equação genérica que define um filtro Butterworth de grau N.

$$|H(j\omega)| = \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}}} \quad (2)$$

Para projetar o filtro, é necessário definir as condições de contorno de acordo com a Figura 6 e as Equações 3 e 4 definidos por HAYKIN e VEEN (2001).

Figura 6 – Condições de projeto do filtro passa baixas.



Fonte:HAYKIN e VEEN (2001).

$$1 - \epsilon \leq |H(j\omega)| \leq 1 \quad \text{para} \quad 0 \leq |\omega| \leq \omega_p \quad (3)$$

$$|H(j\omega)| \leq \delta \quad \text{para} \quad |\omega| \geq \omega_s \quad (4)$$

Resolvendo as equações apresentadas em 3 e 4 utilizando a equação do filtro Butterworth 2, encontra-se o polinômio de resposta maximamente plana que representa o filtro especificado.

3.5 Aprendizado de Máquina

Aprendizado de máquina é um subcampo da inteligência artificial que se concentra no desenvolvimento de algoritmos e modelos estatísticos que capacitam computadores a executar tarefas específicas sem a necessidade de instruções explícitas, e normalmente envolvem o treinamento de um modelo em um conjunto de dados, onde o modelo ajusta seus parâmetros internos, comumente referidos como pesos, para minimizar o erro em suas previsões. Esse processo geralmente inclui o uso de uma função objetivo para medir o erro e a aplicação de técnicas de otimização para aprimorar o desempenho do modelo ao longo do tempo. O aprendizado de máquina pode ser categorizado em diversos tipos, incluindo aprendizado supervisionado, não supervisionado e por reforço, cada um com seus próprios métodos e aplicações. O aprendizado supervisionado, por exemplo, envolve o treinamento de um modelo em dados rotulados, enquanto o aprendizado não supervisionado lida com dados não rotulados para descobrir padrões ocultos (LECUN; BENGIO; HINTON, 2015).

3.5.1 Aprendizado supervisionado

São algoritmos que aprendem a partir de dados rotulados para realizar previsões ou classificações em novos dados não vistos (LECUN; BENGIO; HINTON, 2015). A seguir, estão alguns tipos comuns de modelos de aprendizado supervisionado:

- **Regressão Linear:** Utilizada para prever resultados contínuos. Este modelo captura a relação entre as variáveis de entrada e a saída ajustando uma equação linear.
- **Regressão Logística:** Aplicada em tarefas de classificação binária. Ela estima a probabilidade de que uma determinada entrada pertença a uma categoria específica.
- **Árvores de Decisão:** Um modelo em forma de árvore que toma decisões com base em uma série de perguntas sobre as características de entrada. É intuitivo e de fácil interpretação.
- **Florestas Aleatórias:** Um método de conjuntos (do inglês, *ensemble*) que combina múltiplas árvores de decisão para melhorar o desempenho e controlar o sobreajuste. Ele agrega as previsões de várias árvores para tomar uma decisão final.
- **Máquinas de Vetores de Suporte (SVM, do inglês *Support Vector Machine*):** Um modelo que encontra o hiperplano que melhor separa diferentes classes no espaço de características. É especialmente eficaz em espaços de alta dimensionalidade.

- **k-Vizinhos mais próximos** (k-NN, do inglês *k-Nearest Neighbors*): Um algoritmo simples que classifica um ponto de dados com base na classe majoritária de seus k vizinhos mais próximos no espaço de características.
- **Redes Neurais**: Inspiradas no cérebro humano, essas redes consistem em camadas de nós interconectados, chamados neurônios, que conseguem aprender padrões complexos nos dados. O aprendizado profundo, uma subcategoria das redes neurais, envolve múltiplas camadas e é particularmente poderoso para tarefas como reconhecimento de imagens e fala.
- **Redes Neurais Recorrentes** (RNNs): São uma classe de redes neurais projetadas para lidar com dados sequenciais, como séries temporais ou textos. Ao contrário das redes neurais tradicionais, as RNNs possuem conexões recorrentes que permitem que a informação de estados anteriores seja levada em consideração na tomada de decisões subsequentes. Isso torna as RNNs particularmente eficazes para tarefas em que o contexto ou a ordem dos dados é crucial.

Esses modelos são treinados utilizando conjuntos de dados rotulados, onde as características de entrada e os rótulos correspondentes são conhecidos, permitindo que o modelo aprenda o mapeamento entre eles e faça previsões em novos dados.

3.5.1.1 Redes Neurais

As redes neurais são uma classe de modelos de aprendizado de máquina inspirados na estrutura e função do cérebro humano. Elas consistem em camadas interconectadas de nós, ou neurônios, que processam dados e aprendem a reconhecer padrões (LECUN; BENGIO; HINTON, 2015). A seguir, são apresentados os principais componentes e conceitos relacionados às redes neurais:

- **Estrutura**
 - Camada de Entrada: A primeira camada que recebe os dados de entrada. Cada neurônio nesta camada representa uma característica do dado de entrada.
 - Camadas Ocultas: Uma ou mais camadas entre as camadas de entrada e saída, onde ocorre o processamento e o aprendizado efetivo. Cada neurônio nessas camadas aplica uma transformação ao dado que recebe.
 - Camada de Saída: A camada final que produz a saída da rede, que pode ser uma classificação, valor de regressão ou outros tipos de previsões.
 - Neurônios: Cada neurônio recebe entradas, aplica uma soma ponderada, adiciona um viés, e passa o resultado por uma função de ativação (como sigmoide, linear retificada, tangente) para introduzir não linearidade no modelo.

- **Pesos e vieses:** Cada conexão entre os neurônios possui um peso associado que determina a força da conexão. Os vieses são parâmetros adicionais que permitem que o modelo se ajuste melhor aos dados.
- **Funções de Ativação:** São funções que determinam a saída de um neurônio com base na sua entrada. Funções de ativação comuns incluem:
 - Sigmoid: Produz valores entre 0 e 1, frequentemente utilizada em classificações binárias.
 - Linear retificada (ReLU, do inglês *Rectified Linear Unit*): Produz a entrada diretamente se for positiva; caso contrário, produz zero. Ajuda a mitigar o problema do gradiente desaparecente.
 - Softmax: Utilizada na camada de saída para classificação multiclasse, convertendo pontuações brutas em probabilidades.
- **Propagação para Frente:** O processo de passar os dados de entrada pela rede para obter uma saída. Cada camada transforma os dados de entrada até que eles alcancem a camada de saída.
- **Função de Perda:** Uma função que mede a diferença entre a saída prevista e os valores-alvo reais. O objetivo do treinamento é minimizar essa perda.
- **Retropropagação:** Um algoritmo utilizado para atualizar os pesos e vieses da rede com base na perda. Ele calcula o gradiente da função de perda em relação a cada peso aplicando a regra da cadeia, permitindo que o modelo aprenda com seus erros.

As redes neurais podem ser categorizadas em vários tipos, com base em sua arquitetura e aplicação:

- **Redes Neurais Propagação para frente:** O tipo mais simples, onde as conexões entre os nós não formam ciclos. Os dados se movem em uma única direção, da entrada para a saída.
- **Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*):** Especializadas no processamento de dados em grade, como imagens. Elas utilizam camadas convolucionais para aprender hierarquias espaciais de características automaticamente.
- **Redes Neurais Recorrentes (RNN, do inglês *Recurrent Neural Network*):** Projetadas para dados sequenciais, como séries temporais ou linguagem natural. Elas possuem conexões que formam ciclos, permitindo que mantenham uma memória das entradas anteriores.

- **Redes Adversariais Generativas** (GAN, do inglês Generative Adversarial Network): Compostas por duas redes (um gerador e um discriminador) que competem entre si para gerar novas amostras de dados que se assemelham a um conjunto de treinamento.

3.5.2 Aprendizado não supervisionado

É um tipo de aprendizado de máquina em que o modelo é treinado com dados que não possuem saídas rotuladas. Nesse método, o algoritmo busca aprender a estrutura subjacente ou a distribuição dos dados sem qualquer orientação explícita sobre o que a saída deveria ser. Algumas das técnicas comuns são métodos de agrupamento, do inglês *clustering*, aprendizado de regras de associação e redução de dimensionalidade.


O aprendizado não supervisionado é particularmente valioso em cenários onde dados rotulados são escassos ou caros para se obter. Ele permite a exploração de dados e a descoberta de padrões ocultos, tornando-se uma ferramenta poderosa em várias aplicações, como segmentação de clientes, sistemas de recomendação e compressão de dados (LECUN; BENGIO; HINTON, 2015).

3.5.2.1 Análise de componentes principais

A PCA é uma técnica estatística amplamente utilizada para a redução de dimensionalidade e extração de características em conjuntos de dados multivariados, tendo como objetivo principal transformar um conjunto de variáveis possivelmente correlacionadas em um conjunto menor de variáveis não correlacionadas, conhecidas como componentes principais. Cada componente principal é uma combinação linear das variáveis originais e é ordenada de modo que o primeiro componente retenha a maior parte da variabilidade presente no conjunto de dados. Os componentes subsequentes capturam a maior parte da variação restante, com a restrição de serem ortogonais (não correlacionados) aos componentes anteriores (GÉRON, 2023).

Uma representação visual da seleção do hiperplano gerado pela PCA Figura 7.

Figura 7 – Seleção do hiperplano de projeção das componentes.



Fonte:Géron (2023).

3.5.3 Aprendizado por reforço

É um tipo de aprendizado de máquina onde um agente aprende a tomar decisões executando ações em um ambiente com o objetivo de maximizar recompensas acumuladas. Diferentemente do aprendizado supervisionado, onde o modelo aprende a partir de dados rotulados, ou do aprendizado não supervisionado, que identifica padrões em dados não rotulados, o aprendizado por reforço se concentra em aprender por meio da interação e do retorno recebido do ambiente (LECUN; BENGIO; HINTON, 2015).

3.6 Métricas de avaliação

A avaliação de classificadores é uma etapa crucial no desenvolvimento de modelos de aprendizado supervisionado, pois permite mensurar o desempenho do modelo de acordo com as necessidades da tarefa. Entre as várias métricas utilizadas para avaliar o desempenho de classificadores, destacam-se *precision*, *recall* e *accuracy*, cada uma representada respectivamente pelas Equações 5, 6 e 7 retiradas de Géron (2023). Cada uma dessas métricas oferece uma perspectiva diferente sobre a qualidade das classificações do modelo.

3.6.1 *Precision*

A métrica *precision* é a proporção de previsões positivas corretas em relação ao total de previsões positivas feitas pelo modelo. Em outras palavras, *precision* indica a capacidade do classificador de não rotular incorretamente uma instância negativa como positiva. É uma métrica particularmente importante em cenários onde os falsos positivos têm um custo elevado.

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

Onde TP são os verdadeiros positivos e FP são os falsos positivos do classificador.

3.6.2 *Recall*

A métrica *Recall*, também conhecido como sensibilidade ou taxa de verdadeiros positivos, mede a proporção de verdadeiros positivos identificados corretamente pelo modelo em relação ao total de instâncias que realmente são positivas. Esta métrica é crucial em situações onde é importante capturar a maioria das instâncias positivas, mesmo que isso signifique aceitar um maior número de falsos positivos.

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

Onde TP são os verdadeiros positivos e FN são os falsos negativos do classificador.

3.6.3 Accuracy

A métrica *accuracy* é a métrica mais intuitiva e amplamente utilizada, representando a proporção de previsões corretas (tanto positivas quanto negativas) em relação ao total de previsões feitas. Embora seja uma métrica útil, especialmente em conjuntos de dados balanceados, a acurácia pode ser enganosa em cenários onde há um desequilíbrio significativo entre as classes.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

Onde TP são os verdadeiros positivos, TN são os verdadeiros negativos, FP são os falsos positivos e FN são os falsos negativos do classificador.

3.6.4 Multiclasse

Quando se trabalha com problemas de classificação multiclasse, onde há mais de duas classes possíveis, as métricas de avaliação precisam ser adaptadas para lidar com essa complexidade.

3.6.4.1 Precision

A métrica *precision* multiclasse pode ser calculada de duas maneiras:

- *Micro Precision*: calcula o total de verdadeiros positivos e falsos positivos somando todas as classes e utiliza estes valores para o cálculo de *precision*;

$$Micro\ Precision = \frac{\sum_{i=1}^N TP_i}{\sum_{i=1}^N (TP_i + FP_i)} \quad (8)$$

- *Macro Precision*: calcula *precision* para cada classe individualmente e, em seguida, tira a média aritmética destes.

$$Macro\ Precision = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i} \quad (9)$$

Onde N é a quantidade de classes do classificador, TP_i são os verdadeiros positivos de cada classe e FP_i são os falsos positivos de cada classe.

No âmbito deste trabalho, será utilizado apenas *macro precision* para apresentação dos resultados.

3.6.4.2 Recall

A métrica de *Recall* multiclasse pode ser calculada de duas maneiras:

- *Micro Recall*: calcula o total de verdadeiros positivos e falsos negativos somando todas as classes e utiliza estes valores para o cálculo de *recall*;

$$\text{Micro Recall} = \frac{\sum_{i=1}^N TP_i}{\sum_{i=1}^N (TP_i + FN_i)} \quad (10)$$

- *Macro Recall*: calcula *recall* para cada classe individualmente e, em seguida, tira a média aritmética dessas precisões.

$$\text{Macro Recall} = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i} \quad (11)$$

Onde N é a quantidade de classes do classificador, TP_i são os verdadeiros positivos de cada classe e FN_i são os falsos negativos de cada classe.

No âmbito deste trabalho, será utilizado apenas a *macro recall* para apresentação dos resultados.

3.6.4.3 Accuracy

A acurácia multiclasse pode ser calculada utilizando a Equação 12.

$$\text{accuracy multiclasse} = \frac{\sum_{i=1}^N TP_i}{\text{Total de elementos da classe}} \quad (12)$$

Onde N é a quantidade de classes do classificador, TP_i são os verdadeiros positivos.

4 Metodologia

Este capítulo descreve a metodologia adotada para alcançar os objetivos da pesquisa, que visa comparar diferentes modelos de detecção de falhas em impressoras 3D. Considerando o caráter exploratório e analítico do estudo, a metodologia foi planejada para assegurar a geração de dados confiáveis e a replicabilidade dos experimentos.

Para atingir os objetivos propostos, cinco etapas principais foram definidas:

- **Criação de um protocolo de preparação e ajuste da máquina:** Este protocolo estabelece as diretrizes para determinar o estado saudável da impressora 3D. Ele define um passo a passo dos ajustes necessários para garantir o funcionamento correto da máquina, incluindo a calibração de componentes e a verificação de parâmetros operacionais.
- **Desenvolvimento de um protocolo sistemático para indução de falhas:** Este protocolo foi projetado para garantir a consistência na coleta de dados durante a indução de falhas. Ele visa assegurar que as falhas sejam introduzidas de forma controlada e replicável, permitindo uma comparação justa entre os diferentes modelos de detecção de falhas.
- **Desenvolvimento de um sistema de aquisição e armazenamento de dados:** Um sistema dedicado foi implementado para capturar e armazenar dados de sensores de vibração durante a operação da impressora 3D. Esses dados serão essenciais para analisar o comportamento da máquina em condições normais e anômalas, e servirão como base para a criação da base de dados.
- **Geração da base de dados:** A base de dados é composta por registros do estado operacional saudável da impressora 3D, bem como de falhas específicas, como problemas na parametrização da temperatura de extrusão, falhas na fixação do carro da ponte rolante do eixo X, e obstruções parciais do bico de extrusão. Esta base de dados será fundamental para a análise comparativa dos modelos de detecção de falhas.
- **Reprodução e comparação de modelos inteligentes:** Utilizando a base de dados gerada, foi feita a adaptação da base de dados e em seguida reproduzidos e treinados modelos de detecção de falhas descritos em estudos anteriores da literatura. Esse processo permitiu uma análise comparativa do desempenho e das características de cada modelo, destacando suas vantagens e limitações.

4.1 Materiais utilizados

Nesta seção serão introduzidos os materiais utilizados no desenvolvimento realizado na metodologia.

Para realização da aquisição dos dados foram utilizados as bibliotecas indicadas na Tabela 1 para programar o Esp32 WROOM-32 com as especificações indicadas na Tabela 2, que por sua vez adquiriu os dados a partir do sensor ADXL345 com especificações indicadas na Tabela 3.

Arduino	2.3.2
Esp32 (Espressif Systems)	3.0.4
Esp32DMASPI	0.6.4
FreeRTOS	202406.01

Tabela 1 – Bibliotecas da aquisição de dados.
Fonte: O autor, 2024.

Processador	Xtensa Dual-Core 32-bit LX6
Memória Flash Programável	4 MB
Memória RAM	520 KBytes
Memória ROM	448 KBytes
Clock máximo	240 MHz
Pinos digitais	25
Tensão de alimentação	4,5 V a 9 V
Portas SPI	2

Tabela 2 – Especificações do Esp32 WROOM-32 utilizado na aquisição.
Fonte: O autor, 2024.

Frequência de aquisição	0,1 - 3200 Hz
Resolução	10 - 13 bits
Amplitude de medição	± 16 g
Fator de escala	$3,9 \frac{mg}{LSB}$
Tensão de alimentação	2,0 V - 3,6 V
Interface de comunicação	SPI ou I2C

Tabela 3 – Especificações do sensor ADXL345.
Fonte: O autor, 2024.

Para armazenamento dos dados adquiridos pela aquisição foi utilizado uma Raspberry Pi 4 com as especificações indicadas na Tabela 4, utilizando o sistema operacional Ubuntu 20.04 e a biblioteca Pigiopio na versão 79.

Para o desenvolvimento dos modelos inteligentes e processamento dos dados adquiridos foram utilizados as especificações de software indicadas na Tabela 5 em conjunto com o computador de especificações indicadas na Tabela 6.

Para realização dos procedimentos foi utilizada a impressora 3D Ender 3 V2 e as impressões utilizaram filamento PLA para construção dos modelos.

Processador	Broadcom BCM2711,quad-core Cortex-A72 64-bit
Clock	1.5 GHz
Memória RAM	4 Gb
SPI	2
GPIOs	40
Alimentação	5 V

Tabela 4 – Especificações da Raspberry pi 4
Fonte: O autor, 2024.

Python	3.12.5
Tensorflow	2.17
Keras	3.4.1
Numpy	1.26.4
Pandas	2.2.2
Scipy	1.14.0
Scikit-learn	1.5.1
Matplotlib	3.9.1

Tabela 5 – Especificações para tratamento dos dados e treinamento dos modelos.
Fonte: O autor, 2024.

Modelo	Dell G15
Processador	AMD Ryzen 7 5800H - 3.20 GHz
GPU	RTX 3060
Memória RAM	16 Gb
Sistema	64 bits

Tabela 6 – Especificações do computador utilizado.
Fonte: O autor, 2024.

4.2 Preparação e ajuste da máquina

Para garantir a qualidade das aquisições na base de dados, é essencial que a impressora 3D esteja em um estado operacional saudável. Isso exige um conjunto de cuidados durante a montagem e calibração da máquina. Dentro do manual da impressora existe um conjunto de etapas descrevendo como realizar a montagem da máquina e sua calibração, entretanto este material se prova incompleto e não descreve todos os cuidados necessários. Esta seção será um complemento ao manual e apresentará os procedimentos padronizados adotados para assegurar que a impressora esteja funcionando corretamente, incluindo os principais cuidados na etapa de montagem, ajustes de componentes e calibração dos parâmetros operacionais.

4.2.1 A impressora

Todos os procedimentos apresentados foram realizados em uma impressora Ender 3 V2 com as especificações apresentadas na Tabela 7, caso outra impressora seja utilizada, os passos devem ser adaptados para o modelo alvo.

Especificações básicas	
Modelo	Ender-3 V2
Método de impressão	FDM
Número de bicos	1
Altura recomendada de camadas	0,1 mm - 0,4 mm
Diâmetro padrão do bico	0,4 mm
Precisão nos eixos X-Y	$\pm 0,2$ mm
Diâmetro do filamento	1,75 mm
Temperatura da mesa	≤ 100 C°
Temperatura do bico	≤ 250 C°
Temperatura da mesa	≤ 100 C°
Sensor de filamento	Não
Eixo Z duplo	Não
Velocidade de impressão	$\leq 180 \frac{mm}{s}$, operação normal 30-60 $\frac{mm}{s}$

Tabela 7 – Especificações da impressora.

Fonte: Adaptado do manual de fábrica Ender 3 V2, 2024.

4.2.2 O material (Filamento)

Um dos pontos mais críticos de uma impressão está na escolha de material que será utilizada, os parâmetros de impressão do material precisam estar dentro das possibilidades de configuração da máquina. O filamento selecionado para o presente trabalho possui as características físicas indicadas na Tabela 8 e os parâmetros recomendados de impressão indicados na Tabela 9.

Propriedades físicas do material (PLA)		
Densidade	1,24 \pm 0,05	$\frac{g}{cm^3}$
Ponto de fusão	165 - 180	°C
Temperatura de transição vítrea	55 - 60	°C
Diâmetro	1,75	mm

Tabela 8 – Características do material de impressão.

Fonte: F3D (2024).

Para decisão dos exatos parâmetros de impressão, é necessário realizar um conjunto de procedimentos de forma a ajustar tais parâmetros para a impressora que está imprimindo, estes procedimentos serão apresentados nas seções seguintes.


Parâmetros recomendados do material (PLA)			
Parâmetro	Mínimo	Máximo	Unidade
Temperatura do bico	205	230	C°
Temperatura da mesa	25	60	C°
Velocidade de impressão	20	60	$\frac{mm}{s}$
Tempo mínimo de camada	10	20	s

Tabela 9 – Parametros recomendados para o material de impressão.
Fonte: Distribuidor do filamento, 2024.

4.2.3 Alinhamento da armação principal

Para que o movimento do eixo Z da impressora 3D ocorra de maneira correta, é fundamental que a armação principal esteja perfeitamente alinhada com a base da impressora, formando um ângulo de 90° com o plano da base, conforme ilustrado na Figura 8.


Figura 8 – Armação principal.



Fonte: O Autor, 2024.

Durante a montagem, é necessário tomar cuidados específicos para garantir que a armação esteja devidamente alinhada tanto na base quanto na parte superior. A fixação das barras laterais é realizada utilizando quatro parafusos na base, como mostrado na Figura 9a. Ao realizar o aperto dos parafusos, é crucial verificar se as barras estão formando o ângulo de 90° com a base, conforme ilustrado na Figura 8. Se este cuidado não for tomado, pode ocorrer uma fixação incorreta, resultando na deformação das barras de alumínio. Após fixar as barras laterais, a barra superior deve ser instalada utilizando mais quatro parafusos, como mostrado na Figura 9b, novamente garantindo que o ângulo de 90° seja mantido.

Figura 9 – Desenhos da montagem do arco.




Fonte: Modificado a partir do manual Ender 3 V2.

4.2.4 Ponte rolante

Na impressora utilizada, o eixo X é suportado por uma ponte rolante posicionada horizontalmente. Para garantir o funcionamento correto, é essencial alinhar essa ponte de modo que ela permaneça paralela ao plano da mesa de impressão, conforme ilustrado na Figura 10.

Figura 10 – Ângulos eixo X.




Fonte: O Autor, 2024.

O alinhamento da ponte rolante deve ser feito através do suporte das roldanas, mostrado na Figura 11a, e pode ser realizado de duas maneiras. Para pequenos desalinhamentos, é possível usar o parafuso excêntrico para ajustar a pressão das roldanas contra o arco principal, forçando o eixo X a se alinhar corretamente. Esse procedimento é ilustrado no item A da Figura 11b. As roldanas devem ser apertadas o suficiente para manter o ângulo de 90° , mas ainda permitir que elas girem livremente com o movimento do eixo Z.

Se o ajuste com o parafuso excêntrico não for suficiente, será necessário desaparafusar o suporte das roldanas, realinhar a ponte rolante e ajustar o ângulo em relação à armação principal, conforme mostrado no item B da Figura 11b.

Figura 11 – Eixo X.




Fonte: Modificado a partir do manual Ender 3 V2.

4.2.5 Carro da ponte rolante

O carro da ponte rolante é equipado com um suporte de roldanas, conforme mostrado na Figura 12, onde estão instalados o bico de extrusão, o bloco de aquecimento e o sensor de temperatura do sistema.

Figura 12 – Carro da ponte rolante.




Fonte: Modificado a partir do manual Ender 3 V2.

Para garantir a fixação adequada do carro, é necessário ajustar a porca excêntrica de modo que as roldanas fiquem pressionadas contra a barra do eixo X. A pressão deve ser suficiente para evitar qualquer movimento indesejado do carro, mas ainda permitir que as roldanas girem livremente sobre a barra. Esse procedimento é ilustrado nas Figuras 13a e 13b.

4.2.6 Calibração do motor de passo da extrusora

Para garantir que o controle de inserção do material esteja correto, é necessário calibrar a distância por passo do motor de passo da extrusora. A seguir, são apresentados os passos para realizar essa calibração:

Figura 13 – Posição de fixação do carro da ponte rolante.



Fonte: Modificado a partir do manual Ender 3 V2.

1. Desconecte o tubo PTFE do engate rápido.
2. Desaparafuse o engate rápido da extrusora, conforme ilustrado na Figura 14a.
3. Passe o filamento pelo sistema da extrusora, alinhando a ponta do filamento com a face da extrusora.
4. Comande a impressora a realizar a extrusão de 100 mm de material, atingindo o estado representado na Figura 14b
5. Corte o filamento junto à face da extrusora e meça o comprimento extrudido.
6. Dentro do sistema da impressora, verifique o atual valor de $K : \frac{steps}{mm}$.
7. No sistema da impressora, verifique o valor atual de $K : \frac{steps}{mm}$
8. Atualize o valor de $K : \frac{steps}{mm}$ utilizando a Equação 13 para compensar qualquer discrepância.
9. Repita o processo a partir do passo 4 até que os resultados sejam satisfatórios.


$$K_{novo} = \frac{K_{atual} * d_{planejada}}{d_{extrudada}} \quad (13)$$

4.2.7 Tensionando as correias

Os eixos X e Y da impressora 3D são controlados por meio de correias, que devem estar tensionadas corretamente para garantir o funcionamento adequado do sistema. A tensão deve ser suficiente para mover o sistema sem que as correias escorreguem, mas não excessiva, para evitar o sobreaquecimento dos motores.


Para ajustar a tensão das correias, utilizam-se os botões rotativos, conforme mostrado nas Figuras 15b e 15a.

Figura 14 – Calibrando extrusora.



Fonte: Modificado a partir do manual Ender 3 V2.

Figura 15 – Botões rotativos dos tensionadores.



Fonte: Modificado a partir do manual Ender 3 V2.

4.2.8 Calibração de parâmetros de impressão

Além dos cuidados com o estado físico da máquina, a configuração correta dos parâmetros de impressão é crucial para o funcionamento adequado da impressora 3D. Esses parâmetros são configurados na ferramenta conhecida como fatiador (do inglês, *Slicer*). O fatiador converte o modelo 3D em diversas lâminas 2D, que podem ser impressas pela impressora.

Com base nessas lâminas, o fatiador também gera todos os comandos necessários para a impressora 3D, incluindo o controle de temperatura, a quantidade de material a ser depositado, a velocidade de movimentação e outros parâmetros essenciais. A configuração correta desses parâmetros é fundamental para garantir a qualidade e a precisão das impressões.

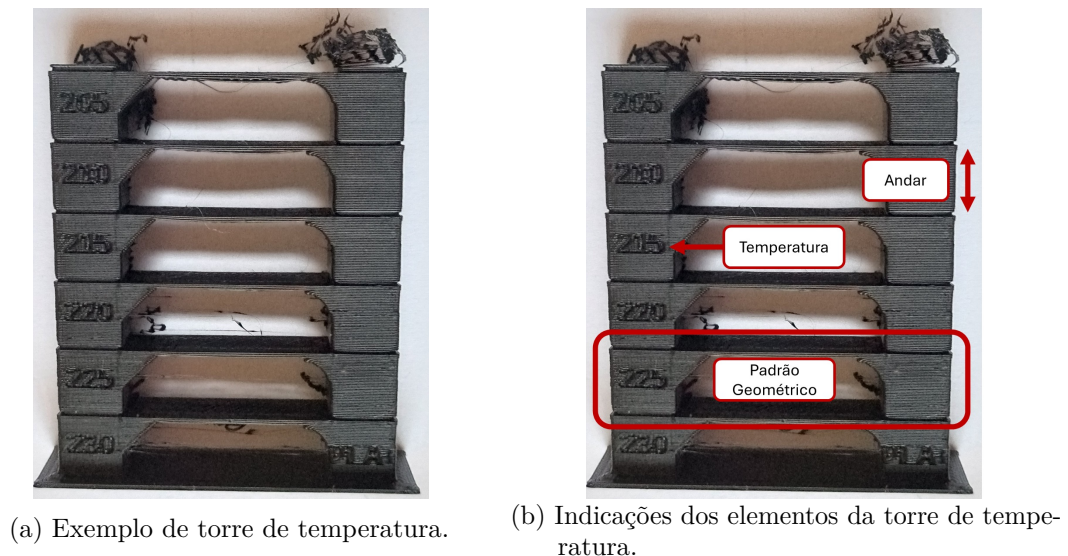
Ajuste de temperatura de extrusão

Para garantir que a extrusão do material ocorra dentro de uma faixa de temperatura adequada, é essencial ajustar a temperatura específica para o material utilizado. Embora os fabricantes geralmente forneçam uma faixa recomendada de operação, um ajuste mais

preciso pode melhorar significativamente o desempenho da impressão, além de evitar possíveis problemas.

Para realizar esse ajuste, utiliza-se frequentemente uma peça chamada torre de temperatura, conforme ilustrado na Figura 16a. Esta peça é impressa com o mesmo padrão geométrico em diferentes andares ao longo do eixo Z, onde cada andar representa uma temperatura diferente predefinida conforme representado na Figura 16b.

Figura 16 – Impressão de torre de temperaturas.



Fonte: O Autor, 2024.

Após a impressão da torre de temperatura, é necessário analisar a peça em busca de sinais de problemas, como descolamento das camadas, deformações na impressão, bolhas ou obstrução do bico de extrusão exemplificados respectivamente nas Figuras 17a, 17b, 17d e 17c. O objetivo é identificar o nível da torre que apresenta a menor quantidade desses problemas, selecionando assim a temperatura ideal para a extrusão.


Ajuste de Retração

A retração é o processo de recuar o material extrudado para interromper a deposição de material, uma ação que ocorre frequentemente durante a impressão. Quando parametrizada incorretamente, pode resultar em fiapos e padrões oscilatórios indesejados nas peças impressas.


Para ajustar a retração, utiliza-se um método semelhante ao de temperatura. Uma torre de retração é impressa com diferentes valores de configuração para cada nível, conforme mostrado nas Figuras 18a e 18b.

Após a impressão, analisa-se a peça para identificar problemas como fiapos ou padrões oscilatórios representados nas Figuras 19a e 19b respectivamente. O objetivo é

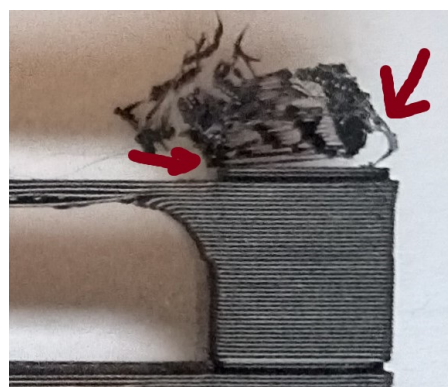
Figura 17 – Exemplos de falhas de impressão.




(a) Descolamento de camadas



(b) Deformação da impressão




(c) Obstrução do bico de extrusão



(d) Bolhas

Fonte: O Autor, 2024.

Figura 18 – Impressão de torre de retrações.



(a) Torre de retração, retrações de 1 mm à 6 mm.




(b) Torre de retração, retrações de 4 mm à 6 mm.


Fonte: O Autor, 2024.

encontrar o nível que apresenta a melhor qualidade de impressão, com a menor quantidade de defeitos.

Figura 19 – Exemplos de falhas de impressão.



(a) Fiapos



(b) Padrão oscilatório

Fonte: O Autor, 2024.


4.2.9 Sensor acelerômetro

Seguindo as recomendações de posicionamento do artigo de Isiani *et al.* (2023), para a aquisição dos dados de vibração, o sensor ADXL345 especificado na Tabela 3 foi fixado próximo ao bico de extrusão, junto ao carro da ponte rolante do eixo X. A fixação do sensor foi feita com a ajuda de uma peça modelada pelo autor, conforme mostrado nas Figuras 20a e 20b. Esta peça se encaixa na parte superior do bico de extrusão, utilizando o mesmo parafuso de fixação da capa externa.

O sensor é então montado na peça com dois parafusos verticais, como ilustrado nas Figuras 20c e 20d. Os cabos de comunicação do sensor seguem o mesmo trajeto dos

cabos do sensor de temperatura e do aquecedor do bico, otimizando a organização e o gerenciamento dos cabos.


Figura 20 – Peça de fixação do sensor.



(a) Modelo da fixação do sensor com as principais medidas. (b) Vista livre do modelo da fixação do sensor.



(c) Vista traseira da fixação do sensor instalado na impressora.



(d) Vista frontal da fixação do sensor instalado na impressora.

Fonte: O Autor, 2024.

4.3 Protocolo para indução de falhas

Para a geração de dados sobre falhas, é essencial criar um ambiente onde falhas possam ocorrer de forma controlada e não destrutiva. O protocolo foi desenvolvido para gerar falhas sistematicamente, o que facilita a coleta de dados relevantes para análise.

Essas falhas são planejadas para garantir que a impressora possa ser restaurada ao seu estado saudável após cada teste. A abordagem permite a observação e aquisição de dados das falhas sem causar danos permanentes à máquina, proporcionando informações valiosas sobre o funcionamento do sistema.

4.3.1 Estado saudável

O estado saudável da impressora é aquele em que a máquina opera corretamente, conforme os parâmetros e ajustes recomendados. Neste trabalho, uma impressora é consi-

derada em estado saudável quando passou por todos os cuidados descritos na Seção 4.2 e produz impressões com resultados visualmente corretos e consistentes. O material utilizado durante todas as impressões da base de dados é o apresentado na Tabela 8, os parâmetros utilizados para impressão estão indicados na Tabela 10.

Parâmetros especificados	
Altura de camadas	0,2 mm
Diâmetro do bico	0,4 mm
Retração	5 mm
Temperatura da mesa	60 C°
Temperatura do bico	210 C°
Velocidade de impressão	50 $\frac{mm}{s}$

Tabela 10 – Parâmetros da impressora.
Fonte: O Autor, 2024.

4.3.2 Temperaturas de extrusão anômala

Devido à necessidade de calibração precisa da temperatura de impressão e do sistema de controle do bico extrusor, podem ocorrer temperaturas inadequadas durante o processo de impressão. Para simular essas condições adversas, foram configuradas diferentes temperaturas de impressão em comparação com o estado saudável, seguindo um método semelhante ao descrito no trabalho de Isiani *et al.* (2023).

Os testes iniciais mostraram que não era possível realizar a impressão a temperaturas abaixo de 205°C, pois o material não atingia o ponto de fusão necessário e não era extrudado. Portanto, os experimentos foram realizados apenas com temperaturas superiores às recomendadas para o estado saudável, sendo escolhidas as temperaturas de 220°C e 230°C para a análise.

4.3.3 Bloqueio parcial do bico de extrusão

Em impressoras FDM, impurezas podem se acumular no bico de extrusão ou o material pode carbonizar devido às altas temperaturas, resultando na redução da área do orifício do bico ou até mesmo na interrupção completa. Para simular essas condições adversas, inspirando-se no trabalho de Isiani *et al.* (2023), que utilizou variações de temperatura para simular bloqueios, este estudo adotou uma abordagem diferente.


Foi realizada a troca do bico de extrusão por bicos de diâmetros menores para simular diferentes graus de obstrução, reduzindo a área do orifício. A Tabela 11 apresenta as especificações dos diferentes diâmetros utilizados e como eles afetam a área do orifício de extrusão e a obstrução relativa resultante.

Nas Figuras 21a e 21b são mostrados os bicos utilizados durante a impressão.

Tamanhos do Bico	Área do orifício	Obstrução Relativa
0.4 mm	0,5026 mm^2	0 %
0.3 mm	0,2827 mm^2	43.75%
0,2 mm	0,1257 mm^2	75 %

Tabela 11 – Especificações das obstruções.
Fonte: O Autor, 2024.

Figura 21 – Bicos utilizados para impressão das peças durante a geração da base de dados.



Fonte: O Autor, 2024.

4.3.4 Carro do eixo X folgado

Um dos principais componentes de movimentação da impressora é o carro do eixo X, descrito na Seção 4.2.5. Durante o funcionamento da impressora, diversas situações podem causar o folgamento do suporte de fixação, como o desgaste das roldanas de borracha e a alteração na posição da porca excêntrica devido à vibração. Para simular esse comportamento, foi realizado o desaperto da porca excêntrica em 90° no sentido anti-horário, criando uma folga que permite pequenos deslocamentos ao longo de outros eixos, mas que não é suficiente para fazer com que o carro se desloque para fora de seu percurso durante sua movimentação.


4.4 Aquisição dos Dados

Para formar uma base de dados robusta, é essencial ter um sistema eficiente para adquirir e armazenar os dados. Nesta seção, serão explicados os principais componentes do sistema de aquisição de dados, incluindo o sensor, o processo de aquisição e o armazenamento dos dados, conforme ilustrado na Figura 22.

4.4.1 Sensor

Com base nas análises de vibração realizadas no trabalho de Isiani *et al.* (2023), foram observadas frequências dominantes em torno de 450 Hz no sistema. Para capturar essas frequências de maneira apropriada, a frequência de amostragem deve ser superior a 900 Hz conforme explicado na Seção 3.2, necessitando ainda levar em consideração o espaçamento para os efeitos do filtro se tornarem efetivos.

Figura 22 – Diagrama do sistema de aquisição dos dados.

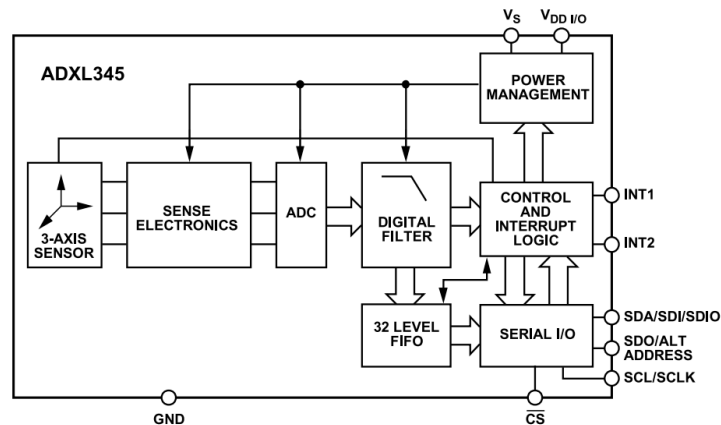


Fonte: O Autor, 2024.

Considerando as limitações de frequência e a disponibilidade no mercado local, optou-se pelo uso do sensor ADXL345. Este sensor é capaz de medir acelerações nos três eixos com uma taxa de amostragem de 0,1 Hz à 3200 Hz abrangendo uma amplitude de ± 16 g ($\pm 156,9064 \frac{m}{s^2}$) e oferecendo uma resolução de 13 bits, convertendo o sinal a partir de um ADC interno e filtrando a frequência de saída de acordo com a frequência selecionada. Além disso, o dispositivo possui dois pinos de saída configuráveis e um sistema de gerenciamento de memória primeiro a entrar, primeiro a sair (FIFO, do inglês *First In, First Out*), com capacidade de armazenamento interno de até 32 amostras simultâneas, acessíveis por meio da Interface Serial Periférica (SPI, do inglês *Serial Peripheral Interface*).

Para a execução das tarefas de aquisição, contou-se com a calibração de fábrica do sensor e as informações de incerteza apresentados na folha de especificações do fabricante.

Figura 23 – Diagrama de blocos funcional ADXL345.



Fonte: Folha de especificações ADXL345, 2024.

No âmbito deste trabalho, os dois pinos de saída do sensor foram configurados de forma que um sinalize quando a FIFO atinja uma quantidade predefinida de amostras e o outro pino sinalize em casos de perda de medições, que acontecem caso a FIFO tenha sua capacidade máxima excedida.

4.4.2 Aquisição

Para realizar a aquisição, um microcontrolador precisa acessar as amostras obtidas pelo sensor via porta SPI e gerenciar os tempos de amostragem para evitar a perda de dados devido ao preenchimento total da FIFO interna do sensor. Considerando a taxa de aquisição de 3200 Hz e a capacidade de armazenamento de 32 amostras da FIFO, o microcontrolador deve acessar os dados em até 10 ms para prevenir perdas.

Inicialmente, foram realizados testes utilizando o Raspberry Pi 4 com as especificações detalhadas na Tabela 4. No entanto, devido à forma como os temporizadores internos do sistema operacional Linux são organizados, interrupções de tempo superiores a 10 ms podem ocorrer. Mesmo com alta prioridade para a tarefa de aquisição, outras tarefas internas do sistema operacional podem demandar mais tempo de execução, impedindo o retorno imediato à tarefa de aquisição. Como o sistema não foi projetado para tarefas em tempo real, isso torna o Raspberry Pi 4 inadequado para essa aplicação.

Dessa forma, foi decidido utilizar o microcontrolador ESP32 como intermediário para realizar a aquisição dos dados e o envio ao armazenamento. Essa escolha se justifica pela necessidade de um gerenciamento rigoroso dos tempos de aquisição e pela possibilidade de utilizar um Sistema Operacional de Tempo Real (RTOS, do inglês *Real Time Operating System*) chamado FreeRTOS. O FreeRTOS permite a execução de múltiplas tarefas com tempos de resposta predefinidos. Com ele, o ESP32 pode realizar a aquisição dos dados do sensor de forma consistente, sem exceder os limites de tempo estabelecidos, evitando a perda de dados.


Considerando a taxa de amostragem de 3200 Hz para os três eixos e 16 bits por leitura, o sensor gera 153,6 Kb de dados por segundo. Como a memória do ESP32 é limitada a 520 Kb de RAM e 4 MB de memória flash, o microcontrolador não é suficiente para armazenar todos os dados de uma impressão completa, sendo utilizado apenas como armazenamento temporário.

O sistema de aquisição interno funciona com duas tarefas principais, interligadas por uma fila para transferir dados entre elas, conforme mostrado na Figura 22.

A primeira tarefa recebe a interrupção que indica o preenchimento parcial ou completo da FIFO do sensor através dos pinos digitais e realiza a leitura de todos os dados disponíveis na FIFO via SPI no momento da leitura. Esses dados são salvos em uma estrutura, junto com uma variável de estado que indica qual interrupção causou a leitura, um contador de amostras lidas da FIFO e um contador que registra quantas vezes a FIFO foi lida desde o início do período de aquisição, conforme ilustrado na Figura 24. Essa estrutura é então enviada para a segunda tarefa através da fila.

A segunda tarefa é responsável por enviar os dados da fila para o armazenamento final através de uma segunda interface SPI. Ela preserva a estrutura de dados gerada pela

Figura 24 – Estrutura dos dados.



Fonte: O Autor, 2024.

primeira tarefa, adicionando apenas uma nova variável que indica quantos elementos estão acumulados na fila de comunicação entre as tarefas. Esse processo assegura que os dados coletados sejam armazenados de forma ordenada e sem perda de informações, mesmo durante períodos de alta carga de aquisição.

4.4.3 Armazenamento

O armazenamento dos dados é realizado utilizando um *Raspberry Pi*, que recebe as informações por meio da comunicação SPI e as salva em um disco de estado sólido (SSD, do inglês Solid State Drive). Essa configuração permite o armazenamento de centenas de horas de dados de impressão. A comunicação SPI em modo *Full-Duplex* possibilita que o *Raspberry Pi* não apenas receba os dados, mas também os envie de volta para o ESP32. Essa característica foi aproveitada para implementar um sistema de *feedback*, no qual os dados recebidos são retransmitidos ao ESP32 na próxima transferência. Se o ESP32 detectar qualquer inconsistência nos dados recebidos, a informação é reenviada até que o dado seja confirmado como corretamente recebido.

O *Raspberry Pi* também utiliza os valores que indicam a quantidade de elementos em fila de transferência entre as duas tarefas do ESP32 para determinar o momento ideal de salvar os dados no SSD. Dessa forma, é possível otimizar o processo de armazenamento, garantindo que os dados sejam gravados de forma eficiente e segura, sem sobrecarregar o sistema ou correr o risco de perda de informações.

4.5 Base de dados


A estratégia adotada para a geração da base de dados foi cuidadosamente planejada com o objetivo de minimizar a interferência entre diferentes variáveis, garantindo que cada falha pudesse ser identificada e estudada de maneira isolada. Esse cuidado foi essencial para evitar complicações e ambiguidades que poderiam surgir da sobreposição de falhas, o que, por sua vez, poderia levar a conclusões equivocadas e comprometer a validade dos resultados obtidos.

Para assegurar a clareza na análise dos dados, decidiu-se que, em cada ciclo de impressão, apenas uma falha seria introduzida. Essa falha, uma vez inserida, foi mantida de forma consistente durante todo o processo de impressão referente àquele ciclo específico, permitindo uma observação detalhada e contínua do impacto daquela falha individual no desempenho da impressora.

A impressora utilizada para a realização da aquisição foi a Ender 3 V2, cujas especificações estão detalhadas na Seção 7. Os parâmetros da impressora utilizados durante as impressões da base de dados estão descritos na Seção 4.3.1.

Para a realização das impressões, foi necessário selecionar um modelo 3D adequado. Com o intuito de cobrir diversas atividades desempenhadas durante a impressão, foi escolhido o modelo *Benchy*, mostrado nas Figuras 25. Esse modelo é amplamente conhecido no mundo da impressão 3D por ser um dos primeiros testes de desempenho, utilizado para avaliar múltiplos aspectos do processo de impressão levando ao limite do desempenho esperado da máquina em algumas situações. Além de abranger uma variedade de estados, o *Benchy* pode ser utilizado no refinamento dos parâmetros do modelo inteligente para outras impressoras, especialmente durante o processo de calibração, visto que é amplamente utilizado para esse fim.

Figura 25 – Fotos de uma *benchy* impressa.



Fonte: O Autor, 2024.

A inserção das falhas foi realizada em estrita conformidade com os protocolos detalhados na Seção 4.3, assegurando que todas as etapas fossem executadas de maneira controlada e padronizada. Após cada ciclo de impressão, os cuidados necessários foram tomados para restaurar a máquina ao seu estado saudável, conforme descrito na Seção 4.3.1, garantindo que cada novo ciclo começasse em condições ideais.

Além disso, a ordem de inserção das falhas para cada ciclo de impressão foi deliberadamente randomizada. Essa randomização foi implementada como uma medida

preventiva, com o intuito de evitar a introdução de erros sistemáticos nos dados gerados, o que poderia comprometer a validade e a generalização dos resultados obtidos.

4.6 Classificação Inteligente

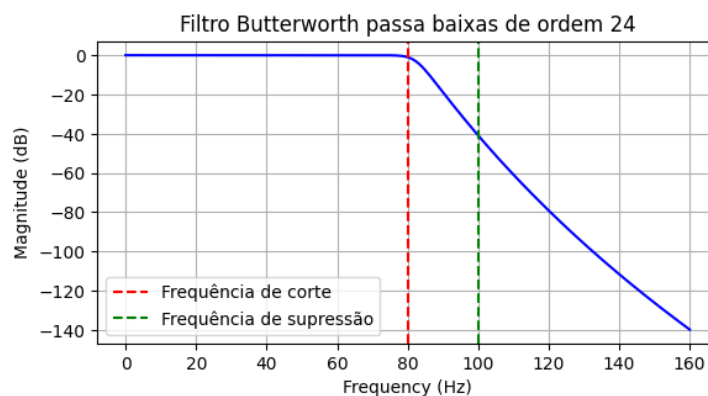
Para obter uma análise inicial do desempenho de modelos inteligentes utilizando a nova base de dados adquirida, foi testado o desempenho dos modelos apresentados no artigo de Khusheef, Shahbazi e Hashemi (2023). Para a completa verificação dos resultados, é necessário realizar a divisão da base de dados em amostras de treino, validação e teste, para este trabalho a divisão utilizada foi de 70%, 20% e 10% respectivamente. Alguns elementos da nova base de dados foram adaptados de forma a reproduzir o formato da base de dados utilizada originalmente no artigo devido às limitações da máquina utilizada e também com o intuito de utilizar de topologias já identificadas com bons desempenhos no reconhecimento de falhas.

4.6.1 Adaptação da base de dados

Trabalho de Khusheef, Shahbazi e Hashemi (2023) para detecção de falhas em impressoras 3D delta, os modelos propostos foram utilizados para detecção de seis estados diferentes da máquina, utilizando três sensores, dois de vibração e um de força com uma aquisição de 200 Hz.

Para adaptar a nova base de dados para condições próximas as da base de dados utilizada no artigo, foi realizada a filtragem e subamostragem do sinal. A filtragem do sinal foi realizada utilizando um filtro Butterworth de 24 polos, explicado na Seção 3.4, com uma frequência de corte de 80 Hz e atenuação de 40 dB à 100 Hz, como representado na Figura 26.

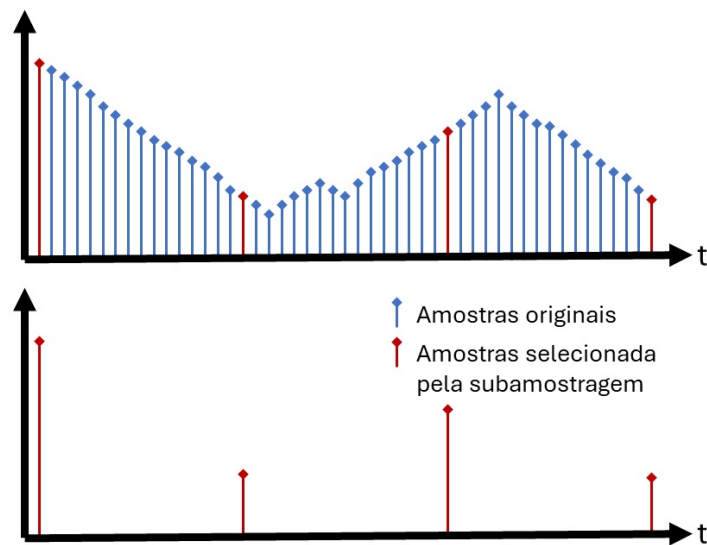
Figura 26 – Resultado do filtro Butterworth.



Fonte: O Autor, 2024.

A subamostragem é realizada após a filtragem do sinal, em conformidade com o teorema de Nyquist, conforme descrito na Seção 3.2, evitando os efeitos de *aliasing*, para evitar os efeitos de *aliasing*. Dado que as taxas de amostragem são múltiplas, foi utilizado o método de subamostragem uniforme. Nesse método, 1 em cada 16 amostras igualmente espaçadas no tempo é selecionada para representar o sinal original. Assim, a frequência de aquisição é reduzida para 200 Hz, como ilustrado na Figura 27.

Figura 27 – Exemplo dos resultados da subamostragem de 3200 Hz para 200 Hz.



Fonte: O Autor, 2024.

O artigo sugere a utilização de modelos clássicos e híbridos para a classificação dos dados, entre os modelos clássicos estão a LSTM padrão, LSTM empilhadas e LSTM bidirecional, entre os modelos híbridos estão CNN-LSTM bidirecional e CNN-LSTM. Além disso foram propostos dois métodos para extração de características, um método de extração manual e outro utilizou de imagens de anomalia geradas a partir dos sinais dos sensores.


4.6.2 Extração manual de características

Com a nova base de dados gerada após a subamostragem, foi realizada a normalização dos dados e em seguida o janelamento, sendo uma janela de 44 amostras com sobreposição de 50%. A partir das janelas extraídas, foi realizada a extração de características, sendo elas média, desvio padrão e a primeira componente da PCA, formando um vetor de 9 características por janela. Para a execução do treinamento, o janelamento da base de dados foi novamente realizada, desta vez com apenas 10 amostras por janela.

4.6.3 Extração de características através de imagens

Ao contrário do método anterior, este método busca representar os dados de entrada como imagens 2D, construídas empilhando os vetores que representam cada um dos sensores, buscando forçar com que todos os sinais de entrada formem vizinhança com os outros sinais, repetindo vetores caso necessário. No caso da base de dados gerada neste trabalho, apenas 3 sensores foram adquiridos, portanto, representando os vetores do sensor de aceleração triaxial com os dígitos de 1 a 3, a imagem pode ser gerada empilhando os vetores na seguinte ordem: 1231. O principal aspecto deste método se encontra na igual chance de vizinhança entre os sensores, desta forma possibilitando a extração de características comuns das classes através da vizinhança balanceada. A janela de amostragem deste método é de 44 amostras, a mesma utilizada na Seção 4.6.2, formando imagens com as dimensões de 44x4. Por último, para aumentar a discriminação visual das imagens, foi extraído o logaritmo da magnitude da transformada de Fourier 2D, um exemplo do resultado se apresenta na Figura 28.

Figura 28 – Imagem formada por amostras de uma impressão saudável.



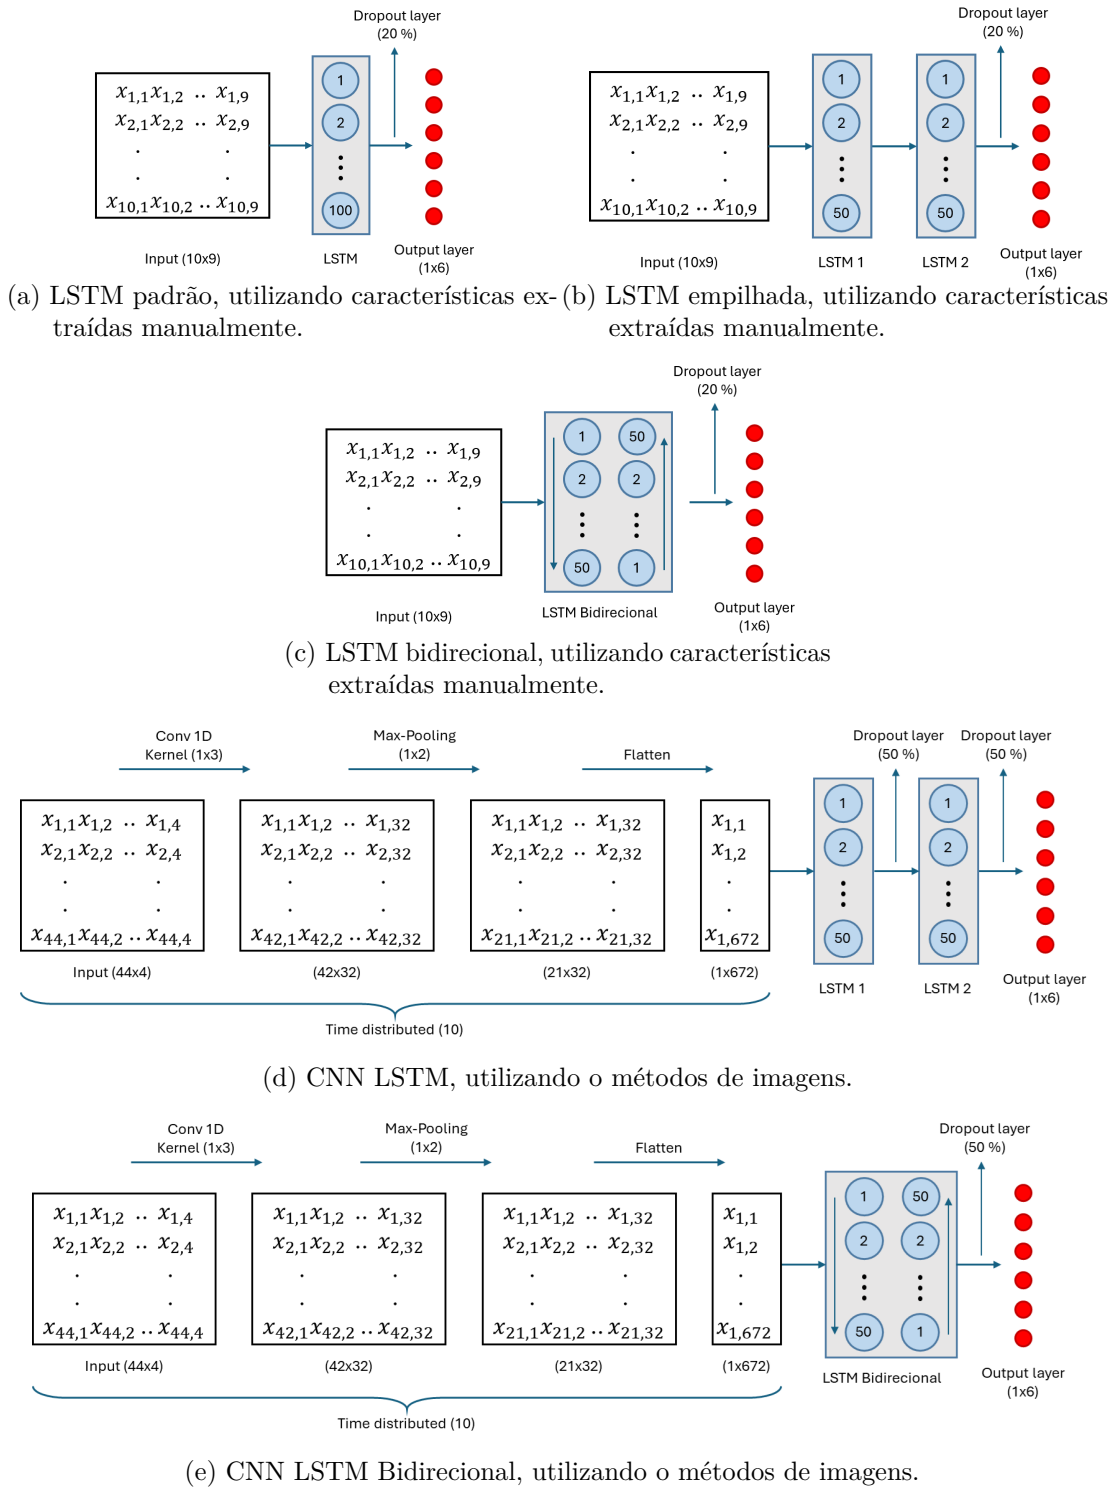
Fonte: O Autor, 2024.

4.6.4 Modelos reproduzidos

O trabalho de Khusheef, Shahbazi e Hashemi (2023) apresentou e treinou diversos modelos de detecção de falhas, com o intuito de comparar resultados, alguns dos modelos foram selecionados para reprodução de resultados, estes estão representados na Figura 29.

Todos os modelos utilizando da função de ativação linear retificada para as camadas ocultas, a inicialização dos pesos é realizada com o método Glorot-uniform, a camada de saída utiliza da função de ativação Softmax, características que não foram citadas no artigo foi assumido os valores padrões da biblioteca Keras.

Figura 29 – Modelos de detecção de falhas reproduzidos.



Fonte: Adaptado de Khusheef, Shahbazi e Hashemi (2023).

5 Resultados

A base de dados gerada e os códigos utilizados para treinamento dos modelos se encontram no repositório deste trabalho (CUNHA, 2024).

5.1 Base de dados

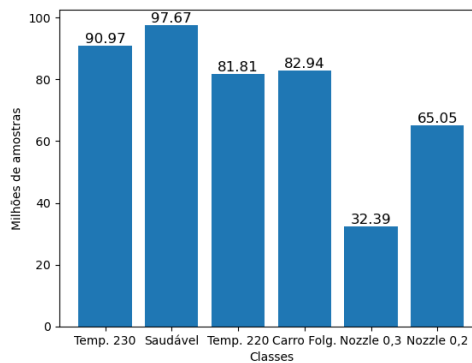
A quantidade de impressões realizadas de cada um dos estados está representada na Tabela 12. Devido à problemas no equipamento de aquisição, não foi possível continuar o recebimento dos dados, desta forma a base de dados não pôde ser adquirida por completo e se tornando desbalanceada.

Estado da máquina	Impressões realizadas
Saudável	7
Temperatura 230 °C	6
Temperatura 220 °C	5
Carro do eixo X folgado	5
Bico de extrusão 0,2 mm	3
Bico de extrusão 0,3 mm	2

Tabela 12 – Quantidades de impressões realizadas por estado da máquina.
Fonte: O Autor, 2024.

Cada aquisição possui cerca de 16,5 milhões de amostras, e como resultado das aquisições realizadas uma base de dados foi gerada, a distribuição de amostras por classe resultante é apresentada na Figura 30.

Figura 30 – Distribuição de amostras por classe.




Fonte: O Autor, 2024.

Os resultados dos modelos impressos em cada um dos estados da máquina estão exemplificados nas Figuras 31a, 31b, 31b, 31c, 31d e 31e.


Figura 31 – Fotos dos modelos impressos em cada um dos estados da máquina.



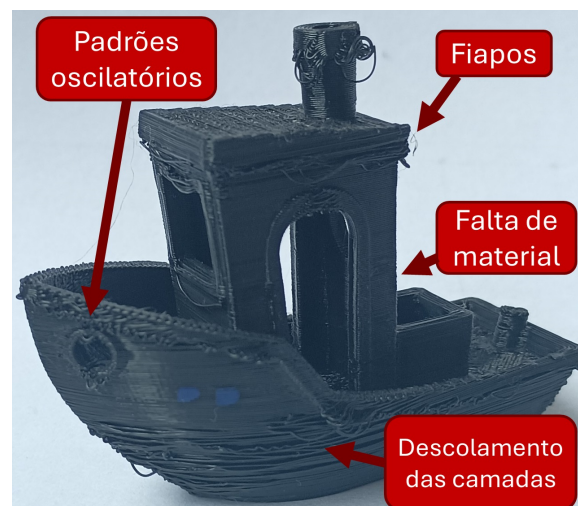
(a) Saudável




(b) Temperatura 220 °C



(c) Temperatura 230 °C



(d) Bico 0,3 mm



(e) Bico 0,2 mm

Fonte: O Autor, 2024.

5.2 Reprodução de modelos da literatura

Os resultados dos modelos replicados de Khusheef, Shahbazi e Hashemi (2023) para detecção de falhas estão apresentados na Tabela 13.

Modelos	<i>Precision</i>	<i>Recall</i>	<i>Accuracy</i>
Vanilla	0.7254	0.7125	0.6966
LSTM Empilhada	0.7314	0.6828	0.7002
LSTM Bidirecional	0.7203	0.6805	0.6933
CNN LSTM	0.7002	0.672	0.6734
CNN LSTM bidirecional	0.6931	0.6553	0.6676

Tabela 13 – Resultado dos modelos de aprendizado de máquina.
Fonte: O Autor, 2024.

Com base nos resultados apresentados, observa-se que, entre os modelos testados, a LSTM Empilhada apresentou o melhor desempenho, com um *precision* de 0.7314, um *recall* de 0.6828 e uma *accuracy* de 0.7002. Em contraste, os modelos híbridos mostraram o menor desempenho. Esses resultados divergem significativamente dos melhores resultados obtidos no artigo base, que alcançou uma *accuracy* de 0,9840 utilizando o modelo CNN LSTM.

Ao analisar o desempenho individual das classes nas matrizes de confusão, representadas na Figura 32, nota-se uma dificuldade considerável em diferenciar entre as classes “saúdável”, “temperatura 220°C” e “temperatura 230°C”. Essa dificuldade é compreensível, dado que a única diferença entre essas classes é a temperatura do bocal, e todas estão dentro da faixa de temperatura especificada pelo fabricante na Tabela 8. Portanto, o modelo parece ter dificuldades em distinguir entre temperaturas que estão dentro da faixa de refinamento especificada.

Ainda em relação às matrizes de confusão, observou-se uma dificuldade semelhante na diferenciação entre as classes de obstruções com bico de 0,3 mm e 0,2 mm. No entanto, devido ao desbalanceamento e à quantidade reduzida de dados para essas classes, é possível atribuir o desempenho inferior à insuficiência de dados para o treinamento. Apesar disso, o modelo parece conseguir identificar quando uma falha de obstrução está ocorrendo.

O comportamento observado durante as épocas de treino está indicado nas Figuras 34 e 33, que mostram os resultados para os modelos simples e híbridos, respectivamente.

Comparando diretamente com os resultados do artigo base, os modelos testados apresentaram um comportamento oposto. Enquanto os modelos com extração de características manuais demonstraram uma maior estabilidade ao longo das épocas, os modelos híbridos exibiram um comportamento mais instável e uma incidência significativamente maior de sobreajuste com o passar das épocas. Em particular, os modelos LSTM Bidirecional e CNN LSTM Bidirecional, representados nas Figuras 34c e 33b, foram os que


Figura 32 – Matriz de confusão dos modelos treinados.




(a) LSTM Vanilla




(b) LSTM Stacked



(c) LSTM Bidirecional



(d) CNN LSTM




(e) CNN LSTM Bidirecional


Fonte: O Autor, 2024.

apresentaram os maiores índices de sobreajuste. Isto pode indicar que a quantidade de dados utilizada ainda é insuficiente para extrair todo o potencial dos métodos híbridos.

Figura 33 – Gráfico da *accuracy* dos modelos híbridos pelas épocas de treinamento.



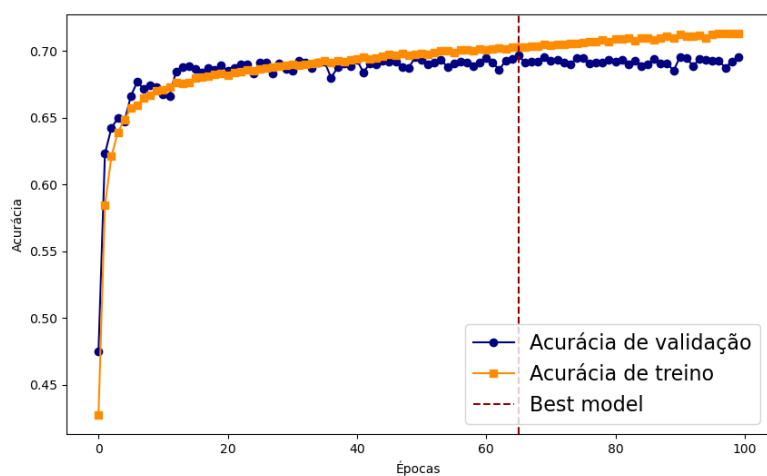
(a) CNN LSTM




(b) CNN LSTM Bidirecional

Fonte: O Autor, 2024.


Figura 34 – Gráfico da *accuracy* dos modelos clássicos pelas épocas de treinamento.



(a) LSTM Vanilla



(b) LSTM Stacked



(c) LSTM Bidirectional

Fonte: O Autor, 2024.

6 Conclusões

Devido a problemas com os equipamentos, a base de dados foi reduzida, resultando em um grande desbalanceamento na quantidade de amostras entre as classes. Os resultados dos modelos refletem os efeitos desse desbalanceamento, apresentando menores índices de acerto nas classes com menor quantidade de amostras.

Ao contrário do previsto pelo artigo de Khusheef, Shahbazi e Hashemi (2023), os modelos que utilizaram extração manual de características não apenas apresentaram um desempenho superior na classificação, mas também se mostraram mais estáveis durante o treinamento. Com base nas comparações realizadas neste trabalho, esses modelos foram os melhores na classificação de falhas em impressoras 3D.

A divergência de acurácias entre os modelos treinados com a base de dados gerada neste trabalho e os modelos treinados com a base de dados do artigo fonte pode ser explicada pela diferença nas entradas utilizadas. Apesar das tentativas de adaptação, a base de dados gerada não inclui todos os sensores utilizados originalmente. Esse ponto acentua ainda mais as preocupações levantadas em trabalhos anteriores (HE *et al.*, 2018), (BAEK; KIM; LEE, 2024) e (ISIANI *et al.*, 2023), que avaliaram os desempenhos a partir das entradas dos modelos e a importância relativa de cada entrada na classificação. Além disso, ressalta a necessidade de uma base de dados aberta para pesquisadores, a fim de permitir uma comparação justa entre os diferentes modelos propostos na literatura.

6.0.1 Trabalhos Futuros

A base de dados gerada por este trabalho pode ser considerada um primeiro passo importante para a melhoria dos modelos de detecção e classificação de falhas, fornecendo um elemento comparativo para estudos futuros. No entanto, ela ainda é insuficiente para treinamentos que exigem grandes volumes de dados. Portanto, aumentar a quantidade de amostras e balancear as classes, são etapas cruciais para ampliar as pesquisas que podem se beneficiar da base de dados final.

O sistema de aquisição desenvolvido mostrou-se eficaz na coleta de dados a partir de um único sensor triaxial de aceleração, com alta taxa de aquisição, e ainda permite expansão através da segunda porta SPI do Raspberry Pi. Contudo, a expansão do sistema pode ser limitada pela quantidade de portas SPI disponíveis e pela taxa de dados que essas portas suportam, especialmente quando múltiplos sensores estão realizando a aquisição simultaneamente. Uma solução possível para esse problema seria a adoção de um protocolo de comunicação com maior taxa de transmissão ou que permita o envio paralelo de dados sem conflitos de portas, como o protocolo MQTT. Essa mudança permitiria a

adição de mais sensores durante a aquisição, evitando limitações impostas pelas portas de comunicação e facilitando estudos sobre os tipos de sensores e seu posicionamento nas tarefas de classificação e detecção de falhas.

Referências Bibliográficas

BAEK, S. Multivariate sensor data analysis for fault detection toward feedback loop-based continuous learning in FFF 3D printer. *International Journal of Advanced Manufacturing Technology*, v. 132, n. 11-12, p. 5975–5988, 2024. ISSN 02683768 (ISSN).

BAEK, S.; KIM, B. S.; LEE, Y. Empirical analysis of sensor type importance for data preparation of real-time operational status monitoring in fused deposition modeling 3D printers. *The International Journal of Advanced Manufacturing Technology*, v. 132, n. 5-6, p. 2617–2630, maio 2024. ISSN 0268-3768, 1433-3015.

BALBINOT, A.; BRUSAMARELLO, V. *Instrumentação E Fundamentos De Medidas - Volume 2*. [S.l.]: LTC, 2019.

BHATTACHARYA, M.; PENICA, M.; O'CONNELL, E.; HAYES, M. AI-driven real-time failure detection in additive manufacturing. In: Longo F.; Shen W.; Padovano A. (Ed.). *Procedia Comput. Sci.* [S.l.]: Elsevier B.V., 2024. v. 232, p. 3229–3238. ISBN 18770509 (ISSN).

CASTILLO, M.; MONROY, R.; AHMAD, R. A cyber-physical production system for autonomous part quality control in polymer additive manufacturing material extrusion process. *Journal of Intelligent Manufacturing*, 2024. ISSN 09565515 (ISSN).

CHOWDHURY, D.; SINHA, A.; DAS, D. XAI-3DP: Diagnosis and Understanding Faults of 3-D Printer with Explainable Ensemble AI. *IEEE Sensors Letters*, v. 7, n. 1, p. 1–4, 2023. ISSN 24751472 (ISSN).

CUNHA, L. K. T. da. *3D printer failure detection*. 2024. <https://github.com/LeoKenny/3D_printer_failure_detection>. Acessado: 20-08-2024.

F3D, F. D. B. *Filamento PLA Premium Preto*. 2024.

<https://www.filamentos3dbrasil.com.br/produtos/filamento-pla-premium-preto/?utm_source=google&utm_medium=paid&utm_campaign=19816643956&utm_content=&utm_term=&gadid=&gad_source=1&gclid=CjwKCAjwiaa2BhAiEiwAQBgYHvLGI49XYFi9Hhx7DekfvlvcIaGyGahpzFJG0V5aIYYr1uJx2Rsr6xoCBwE>. Acessado: 10-08-2024.

FLOYD, T. L. *Sistemas Digitais - Fundamentos e Aplicações*. 9. ed. [S.l.]: Bookman, 2007.

FOROUZAN, B. A. *Comunicação de Dados e Redes de Computadores*. 4. ed. [S.l.]: McGraw-Hill, 2010.

FRANCO, S. *Design with Operational Amplifiers and Analog Integrated Circuit*. 4. ed. [S.l.]: McGraw-Hill, 2015.

FU, Y.; DOWNEY, A.; YUAN, L.; HUANG, H.-T. Real-time structural validation for material extrusion additive manufacturing. *Additive Manufacturing*, v. 65, 2023. ISSN 22148604 (ISSN).

- GUO, J.; WU, J.; SUN, Z.; LONG, J.; ZHANG, S. Fault Diagnosis of Delta 3D Printers Using Transfer Support Vector Machine with Attitude Signals. *IEEE Access*, v. 7, p. 40359–40368, 2019. ISSN 21693536 (ISSN).
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. Beijing: O'Reilly Media, 2023.
- HAYKIN, S.; VEEN, B. V. *Sinais E Sistemas*. [S.l.]: Bookman, 2001. ISBN 9788573077414.
- HE, K.; YANG, Z.; BAI, Y.; LONG, J.; LI, C. Intelligent fault diagnosis of delta 3D printers using attitude sensors based on support vector machines. *Sensors (Switzerland)*, v. 18, n. 4, 2018. ISSN 14248220 (ISSN).
- ISIANI, A.; WEISS, L.; BARDAWEEL, H.; NGUYEN, H.; CRITTENDEN, K. Fault Detection in 3D Printing: A Study on Sensor Positioning and Vibrational Patterns. *Sensors*, v. 23, n. 17, 2023. ISSN 14248220 (ISSN).
- ISO52900 Additive Manufacturing – General Principles – Fundamentals and Vocabulary. São Paulo, BR, 2021.
- KHUSHEEF, A.; SHAHBAZI, M.; HASHEMI, R. Investigation of long short-term memory networks for real-time process monitoring in fused deposition modeling. *Progress in Additive Manufacturing*, v. 8, n. 5, p. 977–995, 2023. ISSN 23639512 (ISSN).
- KIM, H.; LEE, H.; AHN, S.-H. Systematic deep transfer learning method based on a small image dataset for spaghetti-shape defect monitoring of fused deposition modeling. *Journal of Manufacturing Systems*, v. 65, p. 439–451, 2022. ISSN 02786125 (ISSN).
- KORSTEN W. OTTHIUS, F. v. d. H. M. J. *Measurement Science for Engineers*. 2. ed. [S.l.]: Elsevier Science & Technology Books, 2004.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, maio 2015. ISSN 1476-4687.
- LEE, X.; SAHA, S.; SARKAR, S.; GIERA, B. Automated detection of part quality during two-photon lithography via deep learning. *Additive Manufacturing*, v. 36, 2020. ISSN 22148604 (ISSN).
- LI, C.; CABRERA, D.; SANCHO, F.; CERRADA, M.; SÁNCHEZ, R.; ESTUPINAN, E. From fault detection to one-class severity discrimination of 3D printers with one-class support vector machine. *ISA Transactions*, v. 110, p. 357–367, abr. 2021. ISSN 00190578.
- LI, C.; CABRERA, D.; SANCHO, F.; SANCHEZ, R.-V.; CERRADA, M.; OLIVEIRA, J. D. One-Shot Fault Diagnosis of Three-Dimensional Printers through Improved Feature Space Learning. *IEEE Transactions on Industrial Electronics*, v. 68, n. 9, p. 8768–8776, 2021. ISSN 02780046 (ISSN).
- LONG, J.; SUN, Z.; LI, C.; HONG, Y.; BAI, Y.; ZHANG, S. A Novel Sparse Echo Autoencoder Network for Data-Driven Fault Diagnosis of Delta 3-D Printers. *IEEE Transactions on Instrumentation and Measurement*, v. 69, n. 3, p. 683–692, 2020. ISSN 00189456 (ISSN).

LUT, M.; LATIB, L.; AYOB, M.; ROHAZIAT, N. YOLOv5 Models Comparison of under Extrusion Failure Detection in FDM 3D Printing. In: *IEEE Int. Conf. Autom. Control Intell. Syst., I2CACIS - Proc.* [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2023. p. 39–43. ISBN 979-835032130-2 (ISBN).

MALAWADE, A.; COSTA, N.; MUTHIRAYAN, D.; KHARGONEKAR, P.; FARUQUE, M. A. Neuroscience-Inspired Algorithms for the Predictive Maintenance of Manufacturing Systems. *IEEE Transactions on Industrial Informatics*, v. 17, n. 12, p. 7980–7990, 2021. ISSN 15513203 (ISSN).

NIESS, V.; WENDE, S. Intellectual property and product liability challenges in three-dimensional printing [ip corner]. *IEEE Consumer Electronics Magazine*, v. 6, n. 4, p. 128–163, 2017.

OPPENHEIM, A.; SCHAFER, R. *Discrete-Time Signal Processing*. 2. ed. [S.l.]: Prentice Hall, 1999.

PETSIUK, A.; PEARCE, J. Towards smart monitored AM: Open source in-situ layer-wise 3D printing image anomaly detection using histograms of oriented gradients and a physics-based rendering engine. *Additive Manufacturing*, v. 52, 2022. ISSN 22148604 (ISSN).

RACHMAWATI, S.; PUTRA, M.; LEE, J.; KIM, D. Digital twin-enabled 3D printer fault detection for smart additive manufacturing. *Engineering Applications of Artificial Intelligence*, v. 124, 2023. ISSN 09521976 (ISSN).

SIMÕES, F. S. Estudo da relação sinal/ruído na aquisição de dados de sensores de alta impedância. Universidade Estadual de Campinas, 2008.

VOYDIE, D.; GOUPIL, L.; CHANTHERY, E.; TRAVÉ-MASSUYÈS, L.; DELAUTIER, S. Machine Learning Based Fault Anticipation for 3D Printing. In: Ishii H.; Ebihara Y.; Imura J.; Yamakita M. (Ed.). *IFAC-PapersOnLine*. [S.l.]: Elsevier B.V., 2023. v. 56, p. 2927–2932. ISBN 24058963 (ISSN); 978-171387234-4 (ISBN).