

**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

Luis Otávio de Angeles Dias

**Estudo da viabilidade de representações tempo-frequência
como ferramenta de extração de característica para
classificação de padrões de desgaste da ferramenta no
processo de fresamento**

São Carlos

2024

Luis Otávio de Angeles Dias

**Estudo da viabilidade de representações tempo-frequência
como ferramenta de extração de característica para
classificação de padrões de desgaste da ferramenta no
processo de fresamento**

Monografia apresentada ao Curso de Engenharia Elétrica com Ênfase em Eletrônica, da Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Dr. Pedro de Oliveira
Conceição Junior

**São Carlos
2024**

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTA TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E
PESQUISA, DESDE QUE CITADA A FONTE.

S856m	DIAS, Luis Otávio de Angeles Estudo da viabilidade de representações tempo-frequência como ferramenta de extração de característica para classificação de padrões de desgaste da ferramenta no processo de fresamento / Luis Otávio de Angeles Dias ; orientador Pedro de Oliveira Conceição Junior. – São Carlos, 2024. 70 p. : il. (algumas color.) ; 30 cm. Monografia (Graduação em Engenharia Elétrica com Ênfase em Eletrônica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2024. 1. LaTeX. 2. abnTeX. 3. Classe USPSC. 4. Editoração de texto. 5. Normalização da documentação. 6. Tese. 7. Dissertação. 8. Documentos (elaboração). 9. Documentos eletrônicos. I. Junior, Pedro de Oliveira Conceição, orient. II. Título.
-------	--

FOLHA DE APROVAÇÃO

Nome: Luis Otávio de Angeles Dias

Título: “Estudo da viabilidade de representações tempo-frequência como ferramenta de extração de característica para classificação de padrões de desgaste da ferramenta no processo de fresamento”

Trabalho de Conclusão de Curso defendido e aprovado
em 10 / 06 / 2024,

com NOTA 10 (DEZ), pela Comissão
Julgadora:

Prof. Dr. Pedro de Oliveira Conceição Junior - Orientador -
SEL/EESC/USP

Prof. Dr. Augusto Matheus dos Santos Alonso - SEL/EESC/USP

Mestre Paulo Monteiro de Carvalho Monson - Doutorando
EESC/USP

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Professor Associado José Carlos de Melo Vieira Júnior

*Este trabalho é dedicado à comunidade científica brasileira, como uma contribuição
para o desenvolvimento e disseminação da pesquisa científica no país.*

AGRADECIMENTOS

Agradeço aos meus pais, Emerson José Dias e Cristiane Maria Michelazzo de Angeles Dias, por me proporcionarem toda a educação e apoio financeiro para que eu conseguisse ingressar na universidade e concluir o curso. Eles foram essenciais para que eu chegasse até aqui.

Agradeço à minha irmã, Mariana de Angeles Dias Izeli, que junto aos meus pais sempre me acolheu e apoiou as minhas decisões.

Agradeço ao Prof. Dr Pedro de Oliveira Conceição Junior por toda a orientação. Seus conselhos referente à elaboração deste trabalho, produção e discussão de resultados, foram muito valiosos para minha vida profissional.

Agradeço por fim aos meus amigos, em especial à Júlia Rafael e à Giovana Vendrame Escanfelli, por sempre me acompanharem na minha jornada desde antes do meu ingresso a faculdade e ao Diego Oliveira Bomfim, que além da companhia e de me ajudar com meu crescimento pessoal, foi muito importante, como meu veterano, para me auxiliar a passar pela graduação. Concluo, então, esta seção, agradecendo à minha amiga Aline Tenório Doná, pois sem ela eu não teria superado os desafios da graduação e não conseguiria ter seguido em frente.

"Não deixe ninguém roubar a sua imaginação, sua criatividade ou sua curiosidade. É seu lugar no mundo; é sua vida. Vá e faça tudo o que puder com isso, e faça disto a vida que você quer viver."

Mae Jemison

RESUMO

DIAS, L. O. A. **Representações tempo-frequência para classificação de padrões de desgaste da ferramenta no processo de fresamento.** 2024. 70p. Monografia (Trabalho de Conclusão de Curso) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2024.

O fresamento é um processo crítico de corte de superfícies metálicas de peças com ferramentas girantes chamadas fresas. Um fresamento inadequado pode causar perdas e desperdícios devido ao desgaste das fresas, sendo o desgaste de flanco o mais comum, resultando em vibrações e aumento de temperatura durante o corte, prejudicando a integridade das peças. Neste âmbito, a comunidade científica debruça-se na investigação de técnicas de monitoramento do estado de desgaste da ferramenta. Uma alternativa promissora para a implementação da metodologia supracitada consiste em detectar o desgaste das fresas ao empregar técnicas de Aprendizado de Máquina, como Redes Neurais Convolucionais (CNNs), que são eficazes em identificar padrões em imagens. Destarte, cresce o interesse do emprego das CNNs vinculado à análise de sinais de sensores, convertidos em imagens a partir de ferramentas computacionais. No entanto, há uma preocupação quanto à confiabilidade das ferramentas convencionais de formação de imagens a partir das séries temporais, pois elas podem introduzir ruído e padrões confusos, afetando a confiabilidade das análises das CNNs. Levando isto em consideração, este trabalho de conclusão de curso foca na aplicação de decomposições tempo-frequência como ferramenta de conversão de séries temporais em imagens, a partir do estudo da Distribuição de Wigner-Ville (WVD) aplicada na extração de características de sinais de emissão acústica durante o fresamento. O interesse particular da aplicação da WVD é a sua representação precisa da evolução do espectro de frequências ao longo do tempo, criando imagens mais claras e confiáveis para análise pelas CNNs. Outrossim, a utilização desta ferramenta representa uma abordagem inovadora e pouco explorada na literatura relacionada à manufatura e usinagem. Delimita-se, pois, dois objetivos principais: identificar as bandas de frequência mais relevantes para a distinção dos estágios de desgaste, facilitando a extração de características e reduzindo o custo computacional; e utilizar a WVD para determinar com precisão o estado de desgaste das ferramentas, especialmente o desgaste de flanco, permitindo prever a vida útil das ferramentas e otimizar sua substituição. Este trabalho, portanto, visa contribuir para a aplicação de tecnologias avançadas na indústria, alinhando-se aos princípios da Indústria 4.0 e melhorando a produção e qualidade dos produtos fabricados.

Palavras-chave: Distribuição Wigner-Ville, análise tempo-frequência, extração de características de sinais, fresamento.

ABSTRACT

DIAS, L. O. A. **Time-frequency representations for milling tool wear classification**. 2024. 70p. Monograph (Conclusion Course Paper) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2024.

Milling is a critical process for cutting metal surfaces of parts with rotating tools called end mills. Improper milling can cause losses and waste due to end mill wear, with flank wear being the most common, resulting in vibrations and increased temperature during cutting, compromising the integrity of the parts. In this regard, the scientific community focuses on researching techniques for monitoring the tool wear state. A promising alternative for implementing the aforementioned methodology is to detect end mill wear by employing Machine Learning techniques, such as Convolutional Neural Networks (CNNs), which are effective in identifying patterns in images. Thus, there is growing interest in employing CNNs linked to the analysis of sensor signals converted into images through computational tools. However, there is a concern about the reliability of conventional image formation tools from time series, as they may introduce noise and confusing patterns, affecting the reliability of CNN analyses. Taking this into consideration, this thesis focuses on the application of time-frequency decompositions as a tool for converting time series into images through the study of the Wigner-Ville Distribution (WVD) applied in the extraction of features from acoustic emission signals during milling. The particular interest in the application of WVD is its accurate representation of the evolution of the frequency spectrum over time, creating clearer and more reliable images for CNN analysis. Furthermore, the use of this tool represents an innovative and underexplored approach in the literature related to manufacturing and machining. Therefore, two main objectives are outlined: to identify the most relevant frequency bands for distinguishing wear stages, facilitating feature extraction and reducing computational cost; and to use WVD to accurately determine the tool wear state, especially flank wear, allowing for predicting tool life and optimizing replacement. This work aims to contribute to the application of advanced technologies in the industry, aligning with the principles of Industry 4.0 and improving the production and quality of manufactured products.

Keywords: Wigner-Ville Distribution, time-frequency analysis, signal feature extraction, milling.

LISTA DE FIGURAS

Figura 1 – Exemplo de série temporal convertida em imagem utilizando os algoritmos GASF e GADF	22
Figura 2 – Visualização da fresa e sua cinemática.	26
Figura 3 – Principais tipos de desgaste de ferramenta de usinagem.	28
Figura 4 – Sinais de corrente do motor a) Com funcionamento normal do motor em plena carga; b) Com funcionamento normal do motor sem carga; c) Situação de quebra de lâmina da ferramenta.	33
Figura 5 – Espectros do sinal de força da ferramenta a) Na condição ideal; b) Na situação de desgaste sem rompimento da ferramenta; c) Na situação de quebra da ferramenta.	34
Figura 6 – Montagem utilizada pelo autor	38
Figura 7 – Exemplo de sinal no tempo do caso 1	42
Figura 8 – Exemplo de sinal no tempo do caso 6	43
Figura 9 – Exemplo de sinal no tempo do caso 7	44
Figura 10 – Exemplo de sinal no tempo do caso 8	45
Figura 11 – Exemplo de sinal no tempo do caso 11	46
Figura 12 – Exemplo de sinal no tempo do caso 12	47
Figura 13 – Exemplo de sinal do caso 12 com comportamento anormal no tempo	48
Figura 14 – WVD para três casos críticos do grupo 1	49
Figura 15 – WVD para três casos críticos do grupo 7	50
Figura 16 – WVD para três casos críticos do grupo 8	51
Figura 17 – WVD para três casos críticos do grupo 11	52
Figura 18 – WVD para três casos críticos do grupo 12	53
Figura 19 – Visualização da relação Energia da banda versus desgaste para o grupo 1	54
Figura 20 – Visualização da relação Energia da banda versus desgaste para o grupo 7	54
Figura 21 – Visualização da relação Energia da banda versus desgaste para o grupo 8	55
Figura 22 – Visualização da relação Energia da banda versus desgaste para o grupo 11	55
Figura 23 – Visualização da relação Energia da banda versus desgaste para o grupo 12	56
Figura 24 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 1	56
Figura 25 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 7	57
Figura 26 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 8	57
Figura 27 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 11	58

Figura 28 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 12	58
Figura 29 – Visualização, da relação entre B/A e desgaste para o grupo 1	59
Figura 30 – Visualização, da relação entre B/A e desgaste para o grupo 7	59
Figura 31 – Visualização, da relação entre B/A e desgaste para o grupo 8	60
Figura 32 – Visualização, da relação entre B/A e desgaste para o grupo 11	60
Figura 33 – Visualização, da relação entre B/A e desgaste para o grupo 12	61
Figura 34 – Visualização de algumas WVD's filtradas em B e A	62
Figura 35 – WVD para sinal do caso 11 correspondente a alto nível de desgaste . .	63
Figura 36 – Curvas ROC e matriz de confusão para avaliação das previsões realizadas pela rede neural treinada.	64

LISTA DE TABELAS

Tabela 1 – Condições experimentais.	39
Tabela 2 – Condições experimentais adicionais.	39

LISTA DE ABREVIATURAS E SIGLAS

WVD	Distribuição de Wigner-Ville
CNN	Rede Neural Convolucional
AI	Inteligência artificial
ML	Machine learning
GASF	Campos de Soma Angular de Gramian
GADF	Campos de Diferença Angular de Gramian
MTF	Campos de Transição de Markov
STFT	Transformada de Fourier de Tempo Curto
WT	Transformada de Wavelet
DL	<i>Deep Learning</i>
RUL	Remaining Useful life

SUMÁRIO


1	INTRODUÇÃO	21
1.1	Objetivos	23
1.1.1	Objetivo Geral	23
1.1.2	Objetivos Específicos	23
2	DESENVOLVIMENTO	25
2.1	Revisão Bibliográfica	25
2.1.1	Indústria 4.0	25
2.1.2	O processo de fresamento	26
2.1.3	Desgastes da fresa	27
2.1.4	Sensoriamento	28
2.1.5	Sinais de emissão acústica	30
2.1.6	Extração de características de sinais	30
2.1.6.1	Pré-processamento do sinal	31
2.1.6.2	Análise no domínio do tempo	31
2.1.6.3	Análise no domínio da frequência	32
2.1.6.4	Análise tempo-frequência	32
2.1.7	Distribuição de Wigner-Ville (WVD)	34
2.1.8	Redes neurais convolucionais (CNNs)	36
2.2	Material e métodos	37
2.3	Resultados e Discussão	41
3	CONCLUSÃO	65
	REFERÊNCIAS	67

1 INTRODUÇÃO

Os sistemas de inteligência artificial (AI – artificial intelligence) baseados em aprendizado de máquina (ML – machine learning) estão se tornando cada vez mais importantes no monitoramento de condições em processos de manufatura devido às possibilidades de automatização do processo manual e a tomada de decisões em tempo real com base em dados gerados por sensores. Tais algoritmos são capazes de aprender e realizar previsões com base em padrões nos dados de sensores, permitindo identificar, classificar e estimar diferentes tipos de falhas do processo. Esse conceito pode ser implementado em roteiros de manutenção preditiva da condição da ferramenta a fim de evitar que um dano de ordem maior aconteça, contribuindo com a redução no tempo de inatividade e a uma melhoria na eficiência geral das operações de manufatura. Seguindo as novas práticas industriais e o conceito de indústria 4.0, tal intervenção garantirá um processo de manufatura mais inteligente e automatizado, resultando em melhor qualidade e redução de custos (Cinar *et al.*, 2020; Ding *et al.*, 2020; Rai *et al.*, 2021; Serin *et al.*, 2020; Woschank; Rauch; Zsifkovits, 2020). As redes neurais convolucionais (CNNs – convolutional neural networks) se destacam como uma ferramenta com potencial para realização das tarefas acima referidas. São um tipo especializado de rede neural artificial moderna e amplamente usada para reconhecimento e processamento de imagens por meio de algoritmos de aprendizado profundo (DL- deep learning). O princípio básico das CNNs é fundamentado no uso de filtros convolucionais que realizam uma varredura na imagem de entrada e detectam características importantes, como arestas, formatos e padrões. Tais características são convertidas para uma representação compacta por meio de um processo denominado pooling, o qual reduz a resolução espacial enquanto aumenta o nível de abstração dos padrões. O processo é repetido várias vezes, produzindo um conjunto final de características que será validado para tarefas de classificação ou regressão (Faceli *et al.*, 2021; Gu *et al.*, 2018; Haykin, 2009; Li *et al.*, 2022). No caso do escopo deste trabalho, esses algoritmos podem ser treinados para reconhecer padrões que indicam o início do desgaste da ferramenta, prever quando ela precisará ser substituída, classificar diferentes níveis de desgaste e estimação de tempo remanescente de uso. Por outro lado, um desafio científico e tecnológico de uso da CNN está relacionado ao tamanho da sequência. O treinamento destas redes, principalmente utilizando sequências longas, tal como um sinal decorrente do monitoramento de um processo de manufatura, pode se tornar uma tarefa complexa e que irá exigir alta demanda computacional (Geron, 2019). No estudo de (Wang; Oates, 2015), foi desenvolvida uma abordagem para a transformação de séries temporais em imagens, habilitando assim, a capacidade de extração de características das CNN em séries temporais. A metodologia proposta, apresenta dois algoritmos para realização da transformação das séries temporais. Os algoritmos usados foram o GASF (Campos de

Soma Angular de Gramian) e GADF (Campos de Diferença Angular de Gramian). A aplicação destes algoritmos está ilustrada na Figura 1.

Figura 1 – Exemplo de série temporal convertida em imagem utilizando os algoritmos GASF e GADF



Fonte: (Wang; Oates, 2015)

Entretanto, cumpre frisar que a utilização de tais transformações acima referidas para o treinamento das redes neurais levanta questionamentos acerca da interpretação da imagem gerada. Atualmente, existe uma crescente preocupação quanto a adoção de algoritmos de suporte a tomada de decisões baseados em IA e ML, devido a sua característica de “caixa-preta” (black box). Utilizar a estratégia de conversão das séries temporais em imagens se mostrou efetiva, porém, devido ao cenário mencionado previamente, se faz necessário a utilização de ferramentas que sejam capazes de contornar as limitações de treinamento de longa sequencias e forneça maior clareza na interpretação de suas decisões.

Portanto, a proposta do presente estudo é analisar a viabilidade de utilização de representações tempo-frequência como ferramenta para extração de características de sinais complexos fornecendo também a capacidade de correlação da condição da ferramenta de usinagem com base nas alterações no espectro de frequência e comportamento do sinal acústico correspondente. O estudo servirá de base para a implementação de uma arquitetura CNN em duas dimensões (2D) a partir de um trabalho subsequente, o qual poderá se valer de simplificação no processo de treinamento com algoritmos de DL e maior clareza na interpretação dos resultados tendo como entrada os padrões de representação tempo-frequência que serão gerados no presente trabalho. Espera-se que essa implementação contribua para superar os desafios científicos e tecnológicos de uso das redes CNN anteriormente enfatizado. No presente trabalho, as séries temporais baseadas em sinais de emissão acústica ou vibração correspondentes ao desgaste da ferramenta, são

convertidas em imagens, utilizando a distribuição de Wigner-Ville, utilizada por (Scholl, 2021). É de extrema importância enfatizar que a utilização de representações tempo-frequência com uso método Wigner-Ville, por si só, possibilitará diversas contribuições tendo em vista que tanto as séries temporais quanto o conteúdo em frequência de sinais acústicos carregam informações relevantes sobre a ocorrência de danos na ferramenta de usinagem. Isto posto, a representação tempo-frequência será particularmente útil no estudo do conteúdo da frequência variável nos instantes de tempo do sinal, o que pode gerar informações adicionais sobre o nível, intensidade e início do desgaste da ferramenta. A literatura relata abordagens correlatas, utilizando a transformada de Fourier de tempo curto (STFT) (Huang *et al.*, 2021) e transformada wavelet (WT) (Aghazadeh; Tahan; Thomas, 2018). Entretanto, o método Wigner-Ville se apresenta como alternativa ainda não coberta para o escopo do presente estudo. As contribuições do presente estudo serão particularmente direcionadas para o processo de fresamento, uma das principais operações de usinagem por remoção de material no processo de manufatura, sendo que o desgaste da ferramenta de fresagem, denominada fresa, será estudado experimentalmente em diferentes condições de usinagem para validação do método proposto.

1.1 Objetivos

1.1.1 Objetivo Geral

O trabalho proposto visa analisar a viabilidade de utilização de representações tempo-frequência como ferramenta para extração de características relacionadas à condição da ferramenta no processo de fresamento utilizando a distribuição de Wigner-Ville.

Espera-se que os resultados advindos do trabalho proposto sirvam de base para a implementação de uma arquitetura CNN em duas dimensões (2D) a partir de um trabalho subsequente, o qual poderá se valer de simplificação no processo de treinamento com algoritmos de DL e maior clareza na interpretação dos resultados tendo como entrada os padrões de representação tempo-frequência que serão gerados no presente trabalho. Espera-se que essa implementação contribua para superar os desafios científicos e tecnológicos relativos à necessidade de utilização de ferramentas capazes de contornar as limitações de treinamento de longas sequenciais de dados e de fornecer maior clareza na interpretação dos resultados no âmbito do uso prático das redes CNN. Espera-se que os resultados também contribuam para automação do processo de manufatura e otimização da vida da ferramenta nas operações de usinagem.

1.1.2 Objetivos Específicos

- Utilizar representações tempo-frequência por meio de séries temporais baseadas em sinais de emissão acústica ou vibração correspondentes ao desgaste de flanco da

ferramenta que serão convertidas em imagens, utilizando a distribuição de Wigner-Ville.

- Estudar conteúdo em frequência variável nos instantes de tempo do sinal acústico, permitindo gerar informações adicionais sobre o nível, intensidade e início do desgaste de flanco da ferramenta no processo de fresamento.
- Contribuir para a otimização do processo de manufatura por meio de um sistema alternativo de monitoramento do desgaste da ferramenta em diferentes condições de usinagem no processo de fresamento.

2 DESENVOLVIMENTO

2.1 Revisão Bibliográfica

Esta revisão tem como objetivo principal aprofundar os tópicos mencionados no resumo. Inicialmente, discute-se o contexto contemporâneo do setor industrial, focando nas necessidades atuais de aumento da velocidade e precisão na análise de dados para processos de automação. Em seguida, é fornecida uma contextualização do processo de fresamento, central neste trabalho, destacando a problemática abordada. Por fim, aborda-se os principais termos e técnicas necessárias para o monitoramento de processos industriais, desde as metodologias de sensoriamento encontradas na literatura até as ferramentas de extração de características e tomada de decisões, com ênfase na Distribuição de Wigner-Ville, que será utilizada nas análises deste trabalho.

2.1.1 Indústria 4.0

O rápido desenvolvimento tecnológico ocorrido nos últimos anos tem promovido transformações significativas em diversos setores da sociedade. No contexto industrial, tecnologias como o sensoriamento, a computação em nuvem e o aprendizado de máquina desencadearam uma modificação profunda em todos os setores da produção industrial mundial, fenômeno que ficou conhecido como a quarta revolução industrial, ou Indústria 4.0. Como destacado por Monsone em seu estudo sobre a Indústria 4.0 (Monsone; Csapó, 2019), essas tecnologias conferiram às máquinas não apenas a capacidade de executar uma sequência de operações, mas também a capacidade de monitorar e reconfigurar-se automaticamente em um ambiente totalmente automatizado e adaptativo.

Um dos setores que experimentou um impacto significativo devido à revolução tecnológica supracitada é o da manufatura e usinagem. Conforme apontado por Peres em sua pesquisa sobre a Indústria 4.0 (Peres *et al.*, 2020), as tecnologias transformaram os ambientes de manufatura em ambientes mais dinâmicos e interconectados, tornando-os, conseqüentemente, mais complexos e demandando a análise de grandes volumes de dados para a automação. Como consequência, surge o conceito de manufatura inteligente, que, de acordo com a definição de Lins (Lins; Givigi, 2021), é "um conceito geral de sistemas ou processos de manufatura inteligente que utiliza um novo paradigma para facilitar a próxima geração de automação de manufatura" e que "envolve: 1) digitalização; 2) orientação de serviços; 3) equipamentos de automação inteligente e conectados; e 4) rede de fabricação colaborativa para alcançar a produção em massa personalizada, eficiente em termos de custos e flexível."

Esta demanda pela automatização desponta na comunidade científica o interesse


em desenvolver metodologias eficazes e ágeis para processar as extensas bases de dados necessárias para tal. Para o escopo deste estudo, concentrar-se-á no processo de manufatura, o qual será abordado com maior detalhamento nas próximas seções.

2.1.2 O processo de fresamento

O processo de fresamento é amplamente reconhecido como um dos métodos de usinagem mais prevalentes na indústria. É empregado para a fabricação de uma ampla variedade de peças, caracterizando-se por sua capacidade de retirar material da superfície da peça de trabalho, conferindo-lhe formas complexas e um acabamento preciso. Ariokadass ressaltava em sua pesquisa que esse processo é especialmente destacado por sua habilidade de produzir peças com geometrias intrincadas por meio do uso de ferramentas de corte multifacetadas (Ariokadass; Palaniradja; Alagumoorthi, 2012). Em consonância com o pensamento de Ariokadass, Pang et al. menciona que a popularidade do fresamento provém da sua grande variedade de tecnologias disponíveis, grande eficiência de produção, das boas condições de dissipação de calor nos dentes da ferramenta e alta eficiência de produção (Pang *et al.*, 2019).

A ferramenta responsável pelo corte no processo supracitado é chamada de fresa, a qual consiste numa ferramenta cilíndrica metálica composta por vários dentes cortantes, como mostrado na Figura 2. Esta ferramenta realiza o corte girando em torno do seu eixo de simetria e deslizando pela peça, a partir do movimento relativo da máquina com a fresa, numa direção ortogonal com relação ao seu eixo de rotação. A distância de corte coberta pela fresa após uma revolução é chamada de avanço da fresa.

Figura 2 – Visualização da fresa e sua cinemática.



Fonte: (Li *et al.*, 2014)

O processo de fresamento é classificado de acordo com o tipo de acabamento desejado para a peça. O presente estudo se concentra na análise do processo de fresamento frontal, no qual a superfície fresada é ortogonal ao eixo da fresa. Desta forma, o corte da fresa proporciona a retirada de uma camada da superfície da peça, planificando-a.


2.1.3 Desgastes da fresa

O processo de usinagem de peças, invariavelmente implica no desgaste da fresa, resultando na perda gradual de sua precisão de corte. Essa degradação pode acarretar a produção de peças com acabamento inadequado ou danificadas. Conforme salientado por Aitor, em situações nas quais ocorre uma falha no processo de usinagem, uma peça prestes a ser finalizada pode sofrer danos, levando à interrupção da linha de produção e, conseqüentemente, ao aumento dos custos de fabricação (Duo *et al.*, 2021). Dessa forma, torna-se imperativo realizar um estudo aprofundado dos principais mecanismos de desgaste da fresa e compreender suas implicações no contexto do processo de usinagem, a fim de garantir e manter os padrões de qualidade necessários.

De acordo com Trent e Wright, os principais mecanismos de desgaste de uma ferramenta são difusão, adesão e abrasão (Trent; Wright, 2000). A difusão consiste na transferência de átomos de entre metais, no estado sólido. Este fenômeno depende fortemente da temperatura de corte, da duração do contato, afinidade química e intensidade do contato. Já a adesão ocorre entre a ferramenta e o material da peça, ocasionando uma aspereza superficial à ferramenta devido tanto às altas temperaturas e pressões presentes na área de corte como à alta atividade química da superfície inferior do cavaco recém arrancado, ocasionada pela carência desta superfície de camadas protetoras de óxido. Como resultado, a adesão favorece a formação da aresta postiça de corte (APC). Por fim, a abrasão consiste no arrancamento de pequenas partículas da ferramenta, devido ao atrito e das condições de alta temperatura e pressão entre a ferramenta e a peça durante o processo de corte.

Os mecanismos de desgaste supratranscritos, combinados ou isolados, são responsáveis por diferentes tipos de padrões de desgaste na ferramenta. A Figura 3 ilustra os principais mecanismos de desgaste que podem ocorrer numa ferramenta. Entre os seis tipos mostrados na supramencionada, segundo Souto, o desgaste de flanco possui destaque na avaliação da vida de uma ferramenta de corte. Souto define este desgaste como "uma perda do ângulo de folga, promovendo um aumento dos níveis de contato entre a ferramenta e a peça e conseqüentemente, crescimento nos níveis de atrito e todos os problemas por ele causados"(SOUTO, 2007). Conseqüentemente, as pesquisas sobre o monitoramento e controle de desgaste de ferramentas de usinagem geralmente se propõem a estudar o desgaste de flanco, sendo este perfil de desgaste também o foco deste trabalho documentado em questão.

Figura 3 – Principais tipos de desgaste de ferramenta de usinagem.



Fonte: Sandvik, 2005 apud (Calabria, 2014)

2.1.4 Sensoriamento

Os sensores configuram numa oportunidade de monitoramento, remoto e síncrono de processos industriais. Estes equipamentos são responsáveis por captar variáveis físicas tais como temperatura, pressão do ar e som, e traduzi-las em sinais analógicos de tensão e corrente, possibilitando sua manipulação por outros equipamentos, a exemplo de filtros e amplificadores. Estes sinais podem, posteriormente, serem digitalizados a partir de conversores Analógico-Digitais, permitindo o seu compartilhamento em datasets para análises futuras de extração de características a partir de ferramentas computacionais.

Desta forma, a escolha do sensor adequado para a aplicação desejada é de grande importância, na medida que o ambiente agressivo oferecido pela indústria pode prejudicar a sua vida útil, bem como a confiabilidade dos dados oferecidos. Ademais, a natureza do sinal coletado pode não ser apropriada para o monitoramento da atividade desejada, não

sendo sensível o suficiente para interpretar a informação de interesse.

Neste íterim, há numerosos trabalhos na literatura que se concentram em analisar e comparar diferentes sinais para a extração de características em processos industriais, principalmente para métodos de predição de desgaste de ferramentas no processo de usinagem. No seu artigo, Aitor disserta sobre as principais metodologias de análise de desgaste de ferramenta, separando-as em métodos diretos e indiretos. De acordo com Aitor, métodos diretos consistem em sistemas capazes de medir propriedades físicas da ferramenta, como as dimensões, sua rigidez de superfície e temperatura. Em contrapartida, Aitor elucida que os métodos de sensoriamento se configuram em métodos indiretos, pois realizam a aquisição dos sinais produzidos durante o processo de manufatura, como a emissão acústica, vibração, ou corrente de alimentação das máquinas. O autor, então, conclui que os métodos análise indireto são vistos como mais propostas mais viáveis para o contexto industrial, na medida que não requerem a paralisação da linha de produção para fazer as medições nas ferramentas e por serem mais economicamente acessíveis que os métodos de verificação direta (Duo *et al.*, 2021).

Esta ideia é confirmada por Salgado e Alonso, que aplicaram um sistema de monitoramento baseado na corrente do motor e no sinal de som para monitorar em tempo real o desgaste da ferramenta (Salgado; Alonso, 2007). Eles utilizaram a versão de mínimos quadrados da Máquina de Vetores de Suporte (LS-SVM) para estimar a força de corte de alimentação e a análise do espectro singular (SSA) para extrair informações correlacionadas ao desgaste da ferramenta a partir do sinal sonoro. Os resultados mostraram que o método proposto foi rápido e confiável para monitorar a condição da ferramenta.

Barreiro *et al.* desenvolveram um sistema de monitoramento baseado em vibração e emissão acústica (AE) para fresamento de chapas de aço de grande espessura (Barreiro *et al.*, 2017). Através da análise de diferentes estatísticas e da decomposição de sinais, eles conseguiram identificar com confiabilidade os estados de desgaste progressivo, intermediário e avançado da ferramenta.

No estudo conduzido por Mohanraj *et al.*, a análise de desgaste de flanco em processo de fresamento foi realizada utilizando sinais de vibração e técnicas de análise de wavelet (Mohanraj *et al.*, 2021). O estudo envolveu a extração do expoente de Hoelder como uma característica chave e a aplicação de algoritmos de aprendizado de máquina, como Máquinas de Vetores de Suporte (SVM), KNN, Bayes Kernel, Multilayer Perceptron e árvores de decisão, para prever o desgaste da ferramenta. Eles concluíram que os algoritmos de aprendizado de máquina selecionados, principalmente SVM e árvores de decisão, demonstraram alta precisão na previsão do desgaste.

Olufayo e Abou-El-Hosseini também exploraram o uso da emissão acústica para monitorar a vida útil da ferramenta no fresamento de alta velocidade do aço para moldes H13 (Olufayo; Abou-El-Hosseini, 2015). Eles propuseram um esquema de diagnóstico

baseado em múltiplos sensores para categorizar o estado da ferramenta. Este esquema utilizou componentes de características extraídas por meio de estatísticas e da transformada wavelet para servir como entradas para uma rede neural. O estudo observou que a taxa de avanço possui uma correlação negativa com o desgaste.

O estudo de Attanasio et al. apresentou uma abordagem de simulação do desgaste da ferramenta na perfuração de ligas à base de níquel, particularmente Inconel 718 (Attanasio; Faini; Outeiro, 2017). Eles desenvolveram uma sub-rotina personalizada no software DEFORM-3D para simular o desgaste da ferramenta, considerando as atualizações de geometria em função do desgaste. A boa concordância entre os dados previstos e medidos fornece insights valiosos para modelagem e análise de desgaste.

2.1.5 Sinais de emissão acústica

Dentre os processos de sensoriamento possíveis, sinais obtidos de emissão acústica se mostram entre as opções mais razoáveis, e são vastamente explorados na literatura. Estes sinais consistem do resultado do atrito entre a peça e a fresa e das deformações plásticas sofridas durante o processo de corte. De acordo com Zhou, estes sinais são referentes a ondas sonoras de alta frequência, geralmente acima dos 50 kHz (Zhou; Xue, 2018). De acordo com Kuntoğlu, os maiores desafios na captação de sinais de emissão acústica, são que estas são mais susceptíveis a ruído externo e que a captação de sinais de grandes frequências requer altas taxas de amostragem, geralmente acima de 500 kHz, o que eleva o custo computacional envolvido na análise destes sinais (Kuntoğlu; Sağlam, 2021).

Em contrapartida, estes sinais apresentam ótimo desempenho na extração de características. Diniz indica que a dispersão dos valores RMS dos sinais AE se configura numa característica relevante para a detecção de desgaste da ferramenta (Diniz; Sinatora; Bianchi, 2004). Li et al. também apresenta um resultado positivo com relação à utilidade dos sinais de emissão acústica. A equipe comparou sinais acústicos, de vibração e sinais de corrente da máquina para a análise de desgaste em fresa para extração de dados posterior em CNN. A conclusão de Li et al. foi que a análise dos sinais de emissão acústica e vibração mostraram uma exatidão significativamente maior de predição que os sinais de corrente (Li *et al.*, 2019). Bhuiyan observou que a análise conjunta de sinais de emissão acústica e de vibração opera satisfatoriamente na determinação da condição da ferramenta em várias condições de usinagem testadas (Bhuiyan; Choudhury; Dahari, 2014).

2.1.6 Extração de características de sinais

Após a aquisição dos dados a partir dos sinais emitidos durante o processo de usinagem, o próximo passo consiste na extração de características. A literatura apresenta diferentes metodologias de extração de características para a classificação do estado de uma ferramenta de usinagem.

No seu trabalho de revisão sobre as técnicas de monitoramento de quebra de ferramenta em usinagem, Li atesta as metodologias mais utilizadas na literatura no pré-processamento e no processamento de dados. De acordo com o autor, há três principais proximidades tomadas para o processamento de dados para extração de características de sinais: análise no domínio do tempo, no domínio da frequência e no domínio tempo-frequência (Li *et al.*, 2022).

2.1.6.1 Pré-processamento do sinal

A etapa de pré-processamento é feita no intuito de retirar ruído, componentes redundantes e informações irrelevantes dos sinais em análise, desta forma aumentando a eficiência da análise e diminuindo o seu custo computacional. No seu trabalho, Sun realiza a análise da quebra da ferramenta de fresamento a partir de sinais acústicos emitidos no processo. Para tal, realizou um processamento preliminar dos sinais do dataset, retirando 510 amostras do total de 2760 dos sinais acústicos obtidos no processo de fresamento, na medida que estas amostras correspondem aos transientes de início e término do processo de fresamento, sendo que apenas a parcela correspondente ao fresamento estável da peça oferece informações úteis sobre o estado de conservação da fresa (Sun; Hu; Zhang, 2020). Um janelamento semelhante foi realizado por Xie. Neste caso, Xie optou por analisar apenas uma parcela de 500 amostras do total do sinal, correspondentes a três rotações da ferramenta no corte, retirando assim a redundância do sinal (Xie; Li; Lu, 2019).

Em consonância com o realizado no trabalho dos dois autores supramencionados, Shen automatizou a extração da parcela de interesse do sinal de análise. No intuito de reconhecer os transientes de início e fim do corte da peça no sinal de análise, o autor realiza um pré-processamento do sinal a partir de uma janela móvel. Desta forma, a janela de sinal foi considerada como válida para análise apenas ao satisfazer alguns parâmetros de análise (Shen *et al.*, 2021).

No âmbito de retirada do ruído, assim como afirmado por (Wang *et al.*, 2019) e (Yang *et al.*, 2020), o ruído geralmente observado em altas frequências, de tal maneira que a melhor alternativa para sua retirada é a utilização de filtros passa-baixa e passa-banda.

2.1.6.2 Análise no domínio do tempo

Este tipo de análise baseia-se no cálculo de parâmetros estatísticos da série temporal característica do sinal. De acordo com (Li *et al.*, 2022), as principais vantagens das vertentes de análise de sinais no domínio do tempo residem na sua facilidade de interpretação e no seu baixo custo computacional. Um conjunto destes parâmetros estatísticos do sinal foram calculados por Renones, bem como a sua utilidade destes parâmetros na detecção de falha de peças multidentadas. Os parâmetros calculados pelo autor foram potência elétrica média, consumo máximo de energia elétrica, desvio padrão, tempo de pico e integral do

segmento de consumo de energia elétrica, e os resultados concluem que as medidas de máximo, média e desvio padrão foram as medidas mais relevantes para o diagnóstico. (Reñones; Rodríguez; Miguel, 2010). Sob outra perspectiva, Neslušán explorou o cálculo do RMS (*Root Mean Square*), energia absoluta e força do sinal (integral do sinal de tensão retificada ao longo da duração do pacote de forma de onda AE) para (Neslušán *et al.*, 2015).

Por fim, Li adotou como auxílio na sua análise na falha de fresas as matrizes de ordem de estrutura (*order structure matrixes*), responsáveis por gerar imagens a partir das séries temporais dos sinais. Desta forma, o autor postula que, numa performance normal da ferramenta, as imagens geradas pela plotagem dos termos da matriz são simétricas e, quando há a falha, a simetria é deteriorada, como mostra a Figura 4 (Li; Ouyang; Liang, 2008).


2.1.6.3 Análise no domínio da frequência

Nas análises no domínio da frequência, é tomada a FFT, ou alguma outra função equivalente, como a PSD da série temporal do sinal, no intuito de analisar o seu espectro. Desta forma, anomalias na condição de corte da ferramenta de usinagem produz padrões de frequência atípicos em certas faixas de frequência, que podem ser filtrados e utilizados na detecção de desgaste. Pan reitera que, no sinal de força obtido do processo de fresagem, há uma diferença do espectro observado em conformidade com a situação na qual a ferramenta se encontra. Na dinâmica descrita pelo autor, quando a ferramenta encontra-se no seu estágio ideal, apenas é possível observar no espectro do sinal a frequência correspondente à fresagem nas direções X,Y e Z. Já para o caso de desgaste da ferramenta e do seu rompimento, se torna visível, no espectro do sinal, a frequência correspondente à rotação da ferramenta. À vista disso, a distinção entre desgaste e quebra é decorrente do fato que, no primeiro, a componente do processo de fresamento ainda é mais significativa que a frequência correspondente à rotação, sendo o antagônico verdadeiro para o segundo (Pan *et al.*, 2021). Estas dinâmicas são ilustradas na Figura a seguir.

2.1.6.4 Análise tempo-frequência

As ferramentas de análise tempo-frequência de um determinado sinal no domínio do tempo, $x(t)$, retornam, a partir de $x(t)$, o sinal $X(t,f)$, onde t é tempo e f é frequência. Este sinal resultante $X(t,f)$, por sua vez, carrega consigo a informação da distribuição do espectro de frequências do sinal e apresenta a evolução desta evolução ao longo do tempo. De acordo com (Li *et al.*, 2022), as ferramentas de análise no domínio tempo-frequência são muito adequadas para sinais de natureza não estacionária, cujo espectro de frequências varia significativamente durante o período de análise. Ainda de acordo com o autor, as ferramentas de análise tempo-frequência mais comumente utilizadas são a *Short Time Fourier Transform* (STFT) e a transformada de Wavelet. A primeira realiza a varredura da

Figura 4 – Sinais de corrente do motor a) Com funcionamento normal do motor em plena carga; b) Com funcionamento normal do motor sem carga; c) Situação de quebra de lâmina da ferramenta.




Fonte: (Li; Ouyang; Liang, 2008)

distribuição do espectro do sinal realizando a FFT para cada passo de tempo do sinal, já a última difere da primeira melhorando a localização de características em altas frequências a partir de uma janela de frequência variável ((Addison, 2005)).

No contexto da STFT, no processo de análise do sinal feito por Sun, concluiu-se que a falha da ferramenta pode ser observada a partir do surgimento de uma banda de frequência transiente próxima dos 200 kHz (Sun; Hu; Zhang, 2020). O autor também evidencia no seu trabalho que a análise oferecida pela STFT é mais conveniente na análise

Figura 5 – Espectros do sinal de força da ferramenta a) Na condição ideal; b) Na situação de desgaste sem rompimento da ferramenta; c) Na situação de quebra da ferramenta.



Fonte: (Pan *et al.*, 2021)

de perturbações no espectro do sinal que a Wavelet.

2.1.7 Distribuição de Wigner-Ville (WVD)

A Distribuição de Wigner-Ville, como supracitada em seções precedentes, é uma ferramenta de análise tempo-frequência de sinais amplamente empregada em pesquisas a respeito da extração de características de sinais não estacionários. Um dos principais motivos da sua popularidade é apontado por Scholl, que postula que a WVD supera as limitações de resolução de espectro de outras transformadas tempo-frequência usando conceito de autocorrelação (Scholl, 2021). No desenvolvimento matemático da expressão representativa da ferramenta, o autor aponta que a WVD calcula a distribuição de frequência para cada passo de tempo (representado por "t") de um sinal $x(t)$ a partir da transformada de Fourier da autocorrelação instantânea de $x(t)$, que por sua vez é calculada por:

$$R_{xx}(t, \tau) = x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) \quad (2.1)$$

Onde R_{xx} é a autocorrelação instantânea e τ é o atraso. Assim:

$$\begin{aligned}
W(t, f) &= \int_{-\infty}^{\infty} R_{xx}(t, \tau) e^{-j2\pi f\tau} d\tau \\
&= \int_{-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau
\end{aligned} \tag{2.2}$$

Tomando a definição governada pela Equação 2.2, Martin lista as principais propriedades desta ferramenta (Martin; Flandrin, 1985). São elas:

- A variável da frequência é periódica em π ;
- Propriedades translacionais:

$$\text{se } Y(t) := X(t - \tau), \text{ então } W_Y(t, \omega) = W_X(t - \tau, \omega); \tag{2.3}$$

$$\text{se } Y(t) := X(t)e^{i\omega\Delta t}, \text{ então } W_Y(t, \omega) = W_X(t, \omega - \omega_0) \tag{2.4}$$

- Há a interferência de estruturas no plano tempo-frequência devido à característica bilinear da WVD:

$$W_{x_1+x_2} = W_{x_1} + W_{x_2} + 2\Re\{W_{x_1, x_2}\} \tag{2.5}$$

Onde $\Re\{W_{x_1, x_2}\}$ é chamado de termo cruzado (equação retirada de (Scholl, 2021));

A característica bilinear destacada pela equação 2.5 configura-se em um dos desafios no emprego a WVD, na medida que os termos cruzados oferecem conclusões errôneas sobre o espectro do sinal analisado. Este problema, como registrado por Staszewski (Staszewski K. Worden, 1997), pode ser resolvido adicionando uma função de suavização, como mostra a equação a seguir:

$$]W_s(t, f) = \int L(t - t', f - f') W(t', f') dt' df' \tag{2.6}$$

Onde $L(t, f)$ é a função de suavização da distribuição no tempo e na frequência. Quando a WVD é expressa pela equação 2.6, ela geralmente é chamada de *smoothed-pseudo WVD* (SPWVD). A otimização da solução da interferência dos termos cruzados é dependente da escolha da função de suavização mais adequada.

No contexto da implementação computacional da SPWVD, Staszewski apresenta a sua versão discretizada, definida pela equação abaixo:

$$W_x(n, m) = \frac{1}{N} \sum_{k=0}^{N-1} w_x(k) x^*(n - k) x(n + k) e^{-i4\pi mk/N} \tag{2.7}$$

Onde $w_x(k)$ é uma função de janelamento, utilizada para minimizar o efeito de descontinuidade gerado na análise de vetores de tamanho finito.

2.1.8 Redes neurais convolucionais (CNNs)

O desenvolvimento recente da área de inteligência artificial mostra o potencial de auxílio em predição de eventos e tomada de decisão em processos com condições de operação complexas. Em adição a isto, (Ahuet-Garza; Kurfess, 2018) aponta que a inteligência artificial é central para a Indústria 4.0, na medida que esta requer a análise de grandes quantidades de dados para a automatização dos processos. Desta forma, esta tecnologia tem despertado um crescente interesse na comunidade científica na busca por processos de manufatura inteligentes que otimizem tempo e material.

Por exemplo, Chen et al. utilizaram Redes Neurais Artificiais (ANN) e Redes de Crença Profunda (DBN) para prever o desgaste de flanco com base em dados multissensores (Chen; Jin; Jiri, 2018). Eles compararam o desempenho da DBN com ANNs e regressão de suporte vetorial (SVR), observando que a DBN superou significativamente os outros métodos em termos de erro quadrático médio e coeficiente de determinação.

Já Huang et al. propuseram uma nova metodologia para prever o desgaste da ferramenta usando uma Rede Neural Convolucional Profunda (DCNN) (Huang *et al.*, 2020). Eles extraíram características multidomínio (tempo, frequência e tempo-frequência) a partir de sinais multissensores (força de corte tridimensional e vibração) e estabeleceram uma relação direta entre essas características e o desgaste da ferramenta usando a DCNN. A metodologia proposta foi validada usando três conjuntos de dados de ferramentas run-to-failure em operações de fresamento de alta velocidade. Por exemplo, Chen et al. utilizaram Redes Neurais Artificiais (ANN) e Redes de Crença Profunda (DBN) para prever o desgaste de flanco com base em dados multissensores (Chen; Jin; Jiri, 2018). Eles compararam o desempenho da DBN com ANNs e regressão de suporte vetorial (SVR), observando que a DBN superou significativamente os outros métodos em termos de erro quadrático médio e coeficiente de determinação.

Já Huang et al. propuseram uma nova metodologia para prever o desgaste da ferramenta usando uma Rede Neural Convolucional Profunda (DCNN) (Huang *et al.*, 2020). Eles extraíram características multidomínio (tempo, frequência e tempo-frequência) a partir de sinais multissensores (força de corte tridimensional e vibração) e estabeleceram uma relação direta entre essas características e o desgaste da ferramenta usando a DCNN. A metodologia proposta foi validada usando três conjuntos de dados de ferramentas run-to-failure em operações de fresamento de alta velocidade.

Trabalhos como os de Huang et al. têm sido progressivamente mais numerosos na comunidade científica hodierna. Isto é consequência do destaque que as CNNs vêm ganhando, atraindo a atenção de pesquisadores devido à sua capacidade de abstração de

imagens reconhecendo arestas, bordas e outros padrões a partir da aplicação de filtros convolucionais e pelo processo de pooling, como é explicado nos trabalhos de Faceli, Gu e Haykin (Faceli *et al.*, 2021), (Gu *et al.*, 2018), (Haykin, 2009).

No âmbito do trabalho relatado nesta monografia, a CNN é treinada para reconhecer padrões a partir de imagens geradas por ferramentas de extração de características. Desta forma, é possível treinar esses algoritmos para reconhecer padrões que indiquem o início do desgaste da ferramenta, prever quando será necessária a substituição, classificar diferentes níveis de desgaste e estimar o tempo restante de uso (*Remaining useful life* - RUL). Essa abordagem permite uma gestão mais eficiente e proativa da manutenção das ferramentas, otimizando o desempenho e reduzindo custos associados à substituição prematura ou ao uso prolongado de ferramentas desgastadas. Esta metodologia já foi adotada em outros estudos como o de Wang, que propõe uma ferramenta de análise do sinal no domínio do tempo para a análise da CNN (Wang, 2015), porém levanta-se preocupação sobre a validade do emprego destas ferramentas de análise, na medida que as informações podem não ser de fácil interpretação para a rede, fornecendo conclusões duvidosas e susceptíveis a erros.


2.2 Material e métodos

O *dataset* tomado por referência foi obtido do trabalho de (Goebel, 2007) e consiste num conjunto de 167 estruturas *MATLAB*, agrupadas numa única variável, "*mill.mat*", provenientes de passadas para corte de uma máquina de fresamento, do modelo Matsuura machining center MC-510V, dentro de várias condições de operação. Os dados adquiridos provêm de três tipos diferentes de sensores: sensor de emissão acústica, sensor de vibração e sensor de corrente, sendo os dois primeiros medidos tanto para mesa como para a ferramenta de corte (*spindle*). Uma vez que este trabalho concentra-se em análises de sinais de emissão acústica, as informações captadas pelos outros sensores foram desconsideradas. A Figura em anexo mostra a montagem utilizada para o levantamento de dados:

A Figura 6 mostra a base montada utilizada na captação dos sinais de emissão acústica emitidos pela mesa da máquina, fixada à mesa a partir de duas braçadeiras. Nela, fixou-se o sensor de emissão acústica, modelo WD 925 (PHYSICAL ACOUSTIC GROUP, com alcance de frequência de até 2MHz).

No âmbito do procedimento experimental, inicialmente o sinal captado é direcionado ao terminal de entrada simples de um pré-amplificador (marca DUNEGAN/ENDEVCO, modelo 1801, equipado com um filtro passa-alta integrado de 50 kHz). Subsequentemente, este sinal é submetido a uma amplificação por meio de um amplificador dual, especificamente o modelo DE 302A (também da DUNEGAN/ENDEVCO). Consequentemente, o sinal amplificado é encaminhado para um medidor RMS, um dispositivo especialmente construído pelo Laboratório de Mecânica Aplicada (LMA) da Universidade da Califórnia

Figura 6 – Montagem utilizada pelo autor



em Berkeley, ajustado com uma constante de tempo estabelecida em 8,0 milissegundos. Após essa fase, o sinal processado é transmitido por intermédio do cabo UMK-SE 11,25 (PHOENIX CONTACT), que o conduz até uma placa de aquisição de dados de alta velocidade, a MIO-16 (fabricada pela National Instruments). Finalmente, esta placa está integrada a um computador IBM PC 486DX/2-66, onde os dados são devidamente processados e analisados para fins experimentais. Esta sequência de operações garante a integridade e a precisão dos dados coletados durante o experimento.

Um mesmo conjunto de sensores susoditos foi utilizado para a medição de sinais na ferramenta de corte, fixados em furos roscados próximos à fresa. Neste âmbito, o sinal é introduzido no terminal diferencial de um pré-amplificador de emissão acústica, modelo 1801 (DUNEGAN/ENDEVCO), e segue posteriormente o mesmo percurso já delineado para o outro sensor de emissão acústica.

Neste segmento do estudo, a velocidade de corte foi estabelecida em 200 metros por minuto (m/min), equivalendo a uma rotação de 826 voltas por minuto (rev/min). Optou-se por investigar o impacto de duas profundidades de corte distintas, especificamente 1,5 milímetros (mm) e 0,75 mm, sobre o processo de usinagem. Adicionalmente, duas taxas de alimentação foram implementadas, sendo elas 0,5 mm/rev e 0,25 mm/rev, correspondendo a velocidades de avanço de 413 milímetros por minuto (mm/min) e 206,5 mm/min, respectivamente. Para a execução dos ensaios, selecionaram-se dois materiais distintos: ferro fundido e aço inoxidável J45. Para ambos os materiais, utilizaram-se insertos de corte do tipo KC710, cobertos por várias camadas de carboneto de titânio, carbonitreto de titânio e nitreto de titânio (TiC/TiC-N/TiN) em sequência.

Essa configuração experimental resultou em oito conjuntos distintos de parâmetros. Com o intuito de assegurar a reprodutibilidade e a consistência dos resultados, cada configuração foi submetida a uma replicação, utilizando-se um novo conjunto de insertos para a segunda série de experimentos. As dimensões das peças submetidas à usinagem foram padronizadas em 483 mm de comprimento, 178 mm de largura e 51 mm de espessura.

A estrutura final é dividida portanto num total de 16 casos ou grupo de amostras. Cada um deles representa diferentes fresas, operando em diferentes combinações das condições de corte supracitadas e em níveis de desgaste de flanco. Devido à extensão do *dataset* original, apenas quatro foram selecionados para o estudo: casos 1, 6, 8 e 11. O critério adotado para a escolha foi manter a maior diversidade de condições experimentais, visto que os quatro casos cobrem todos os valores dos três parâmetros variados ao longo do processo de amostragem. Os parâmetros de condições de corte mantidos constantes nos casos estão organizados na Tabela 1. Em cada um, a ferramenta correspondente operou várias vezes no fresamento de peças, gerando um número variável de amostras entre os diferentes casos. Após cada passada da fresa, registou-se o valor de desgaste de flanco VB, em milímetros, sendo esta a variável de desgaste monitorada por este trabalho.

Tabela 1 – Condições experimentais.

Caso	Profundidade de corte	Avanço	Material
1	1.5	0.5	1 – ferro fundido
6	1.5	0.25	2 – aço
8	0.75	0.5	2 – aço
11	0.75	0.25	1 – ferro fundido

Entretanto, posteriormente a esta seleção, optou-se por adicionar ao conjunto de casos supracitado os casos 7 e 12, mostrados na Tabela 2, no intuito de aumentar o número de amostras em análise. Desta forma, houve o incremento do número de amostras abarcados por este trabalho de 23 amostras, totalizando 97 imagens. Este aumento foi importante para melhorar o treinamento da CNN e, consecutivamente, a precisão das previsões por ela geradas.

Tabela 2 – Condições experimentais adicionais.

Caso	Profundidade de corte	Avanço	Material
7	0.75	0.25	2 – aço
12	0.75	0.5	1 – ferro fundido

Tomando o *dataset* escolhido, estendeu-se a análise da WVD para todos os sinais por ele abarcados, este trabalho foi realizado integralmente no *software* de simulação MATLAB. Tendo em vista o custo computacional associado a esta análise, os sinais passaram, pois, por uma rotina de pré-processamento, empregada antes do cálculo da WVD. Nela, foram

retiradas seções das séries temporais correspondentes a redundâncias e transientes, de maneira semelhante àquela feita no estudo de Sun, supracitado na revisão bibliográfica (Sun; Hu; Zhang, 2020), na medida que estes não carregam informações relevantes mediante o estado da ferramenta. A determinação destas janelas ocorreu de maneira visual, a partir da observação da plotagem no tempo dos sinais estudados, buscando selecionar exemplares de todos os casos de fresagem abarcados pelo *dataset* sob estudo. Neste ínterim, investigou-se o intervalo tempo no qual os sinais visualizados estabilizavam sua amplitude.

Uma vez os sinais passados pelo pré-processamento e as suas WVDs calculadas, observou-se as imagens formadas. Utilizou-se, pois, as observações dos formatos e padrões percebidos neste conjunto de imagens na determinação das bandas representativas do processo de desgaste.

Destarte, sugeriu-se um conjunto de bandas para a filtragem, e vasculhou-se a validade da sua utilização através de uma abordagem analítica. Nela, calculou-se a energia do sinal em cada banda supracitada, seguindo a equação abaixo:

$$E_x = \sum_{n=f_{min}}^{f_{max}} |X_f(n)|^2 \quad (2.8)$$

onde E_x é a energia do sinal, X_f consiste na Transformada de Fourier do sinal, e f_{min} , f_{max} são os limites inferior e superior da banda de frequência em questão. O Teorema de Parseval garante que a energia do sinal no domínio da frequência X_f é a mesma que a do sinal no domínio do tempo. Repetiu-se este cálculo para todo o espaço amostral, correlacionando simultaneamente os valores registrados de energia ao nível de desgaste através de um gráfico de dispersão. É de interesse afirmar que os valores de energia no gráfico de dispersão foram agrupados considerando somente as bandas de frequência, em detrimento da categorização abordada na Tabela 1, posto que a relação investigada deve ser universal. Já no âmbito da análise multidimensional tempo-frequência, buscou-se também depreender correlações mais gerais entre os padrões vistos nas imagens e o avanço do desgaste, atribuindo menor enfoque na investigação das bandas de frequência à qual estes padrões pertenciam.

Consecutivamente, postuladas as bandas a serem usadas para a análise, aplicou-se um conjunto de filtros passa-banda adequado nos sinais, eliminando os componentes espectrais fora destes intervalos. À vista disso, estas séries temporais foram decompostas em tempo e frequência pela WVD, gerando o conjunto de 97 imagens de análise supracitado.

Pra conclusão do estudo, realizou-se uma etapa extra ao trabalho descrito nesta monografia. Nela, utilizou-se as imagens da WVD dos sinais filtrados para treinar uma CNN, desenvolvida em outro trabalho dentro do grupo de pesquisa do orientador, no intuito de trazer uma confirmação preliminar da eficácia da metodologia proposta a partir da avaliação de dois diferentes níveis de desgaste, de até 0.20 mm e desgastes maiores que 0.20 mm. É crítico observar que esta avaliação feita pela rede neural é extremamente

simples dado a extensão reduzida do conjunto de amostras envolvido na análise, e apresenta funcionalidade apenas para o contexto introdutório no qual ela está inserida. Ocorre que, para resultados tão satisfatórios como os apresentados por algumas referências citadas na revisão bibliográfica, é primordial a utilização de *datasets* da ordem de grandeza de 1000 dados para treinamento (cerca de 10 vezes a extensão deste estudo).

Foi utilizada a arquitetura GoogLeNet. A arquitetura GoogLeNet (Szegedy et al., 2014), foi proposta com 22 camadas de profundidade distribuídos em 7 milhões de parâmetros ajustados durante o seu processo de treinamento. Algumas camadas da rede foram substituídas ou ajustadas para se adequar as características do conjunto de dados. Para contribuir com o aumento do desempenho da rede, foi adicionada uma camada de dropout, cujo papel é evitar o sobreajuste ocasionado pelo número relativamente baixo de amostras disponíveis neste conjunto de dados, descartando uma parte dos neurônios nas camadas ocultas da arquitetura.


O conjunto de dados utilizado nesta seção do estudo, conforme mencionado previamente, possui 97 amostras de sinais obtidos por um sensor de emissão acústica acoplado ao spindle. Para a validação do modelo foi criado um subconjunto específico, contendo 10 % das amostras, que foram excluídas do conjunto de treinamento, para evitar o contato prévio do algoritmo com estes dados. Os hiperparâmetros da rede foram ajustados para otimizar o desempenho do algoritmo durante sua etapa de treinamento. O tamanho do lote de treinamento foi de 32 imagens por iteração, sendo 25 o número máximo de épocas, a taxa de aprendizado da rede de 10^{-4} , o fator de decaimento de gradiente foi de 0,9 e o fator de decaimento de gradiente quadrático foi de 0,999. Ao término da etapa de treinamento do modelo, a performance do algoritmo foi avaliada utilizando o conjunto de teste através da matriz de confusão, para visualizar a precisão das previsões, e através da curva ROC (Receiver Operating Characteristic), para analisar a capacidade do modelo em distinguir entre as classes em diferentes limiares, fornecendo uma medida da eficácia do modelo em termos de sensibilidade e especificidade.

2.3 Resultados e Discussão

No âmbito da investigação da janela de tempo ideal para retirada de transientes dos sinais na rotina de pré-processamento, apresenta-se em sequência as plotagens realizadas no software. Prezando pela objetividade, serão apresentadas apenas os plotes mais relevantes para as discussões.

Na Figura 13, é apresentado um exemplo de sinal cujo comportamento difere consideravelmente dos demais sinais de seu respectivo grupo. Há diversos fatores práticos que potencialmente levaram às deformações supracitadas. Eles incluem a inserção de ruído oriunda de interferência entre o sensor e outros equipamentos no momento da captação dos dados, erros de posicionamento da peça de corte, a presença de peças de menor qualidade

Figura 7 – Exemplo de sinal no tempo do caso 1



entre as utilizadas para corte, e problemas ocasionais na configuração e posicionamento do sensor e dos outros equipamentos utilizados para capturar o sinal acústico. Neste ínterim, as amostras com estas deformações foram descartadas.


Considerando, portanto, os sinais restantes, as Figuras apresentadas permitem concluir que é razoável atribuir uma janela de análise de 40 ms a 70 ms para todos os sinais do *dataset*, visto que este intervalo descarta os transientes de amplitude em todos os casos.

Desta forma, a escolha do novo intervalo do sinal de emissão acústica diminuiu o tamanho do sinal de 9000 amostras para 3000, o que por sua vez consiste numa redução de aproximadamente 67% do *dataset* analisado sem prejudicar a qualidade da análise proposta.

Na sequência, calculou-se a WVD dos sinais. As Imagens de 14 a 18 mostram a WVD de três casos críticos de desgaste de flanco, representado por VB, em milímetros, para cada grupo: desgaste mínimo, desgaste médio e desgaste alto.

Portanto, é possível observar como a evolução do desgaste da ferramenta se manifesta na decomposição tempo-frequência dos sinais de emissão acústica. Fica evidente que, à medida que o valor de VB aumenta, os sinais captados passam a conter mais energia nas bandas de frequência mais elevada. Além disso, no escopo de uma análise

Figura 8 – Exemplo de sinal no tempo do caso 6




tempo-frequência, o avanço da energia do sinal para bandas de frequência mais altas susodito marca alterações significativamente nos padrões presentes na imagem resultante. Para descrever essas diferenças nos padrões, é apropriado utilizar a analogia de que a aparência da imagem correspondente a sinais de maior nível de desgaste se assemelha a uma superfície enrugada. Considerando esta analogia, pode-se afirmar que o avanço do desgaste pode ser observado pelo enrugamento da WVD do sinal de emissão acústica da ferramenta. Estas diferenças de padrões são facilmente detectadas por CNN's.

Analisando cautelosamente a WVD de todos os sinais do *dataset*, propôs-se um conjunto inicial de bandas representativas do processo de desgaste. Neste ínterim, as bandas selecionadas foram: 5 a 6 kHz, 10 a 12 kHz, 15 a 16 kHz, 32 a 33 kHz. No objetivo de realizar uma análise quantitativa da relevância das bandas sugeridas, realizou-se o cálculo da energia do sinal nestas bandas, seguindo a Equação 2.8. Estes valores foram associados com o desgaste da ferramenta nos gráficos de dispersão mostrados nas Figuras de 19 a 23. Vale observar que, para níveis de desgaste não registrados (identificados como $VB = \text{NaN}$ pelo *software*), VB foi considerado 1 mm, de tal maneira a permitir a sua distinção entre os casos de interesse (com valor de VB registrado no *dataset*). Além disso, a unidade de medida do eixo y dos gráficos de dispersão, V^2 , se bem que formalmente não adequada para designar energia, foi empregada para fins comparativos.

A análise dos gráficos de dispersão permite uma série de observações. Primeiramente,

Figura 9 – Exemplo de sinal no tempo do caso 7




é possível perceber que a banda de 15 a 16 kHz pode ser considerada irrelevante para a extração da informação do desgaste da ferramenta. Por outro lado, é possível perceber em todos os grupos que a energia das outras três bandas restantes aumenta de maneira parcialmente consistente na proporção que o desgaste da ferramenta evolui. A única exceção é da banda de 5 a 6 kHz no diagrama de dispersão do grupo 1. Isto evidencia que sinais correspondentes a maiores níveis de desgaste de ferramenta possuem mais energia, devido ao atrito adicional entre a peça e a fresa, decorrente das deformações resultantes do progresso do desgaste de flanco.

Entretanto, é nítido que as proporções pelas quais o valor da energia varia para cada banda não são iguais. Na maioria dos casos, ela é consideravelmente maior para a banda de 32 a 33 kHz, se opondo ao crescimento desacelerado das bandas mais baixas, com destaque para a banda de 5 a 6 kHz. A faixa de 10 a 12 kHz segue uma tendência semelhante à de 5 a 6 kHz, como é embora demonstre um aumento mais significativo geralmente em níveis intermediários de desgaste, como evidenciado nas Figuras 19 e 23. No entanto, também é observado nesta banda um crescimento proporcional da energia em relação ao valor do desgaste, como nos casos 7, 8 e 11.

Consequentemente, as bandas de 5 a 12 kHz, referenciada como banda B, e de 30 a 35 kHz, referenciada como banda A, compõem o novo conjunto de bandas proposto. Desta maneira, aproveita-se do contraste de proporção de crescimento de energia entre as bandas


Figura 10 – Exemplo de sinal no tempo do caso 8



de 32 a 33 kHz e de 5 a 6 kHz, prontamente visualizados pelas modificações nos padrões de formatos e cores das WVD's calculadas dos sinais. Ademais, na medida que B também incorpora a banda de 10 a 12 kHz, consegue-se, para os casos 1 e 12, uma otimização da distinção dos níveis de desgaste intermediários. Esta otimização não traz prejuízo na relação procurada entre WVD e desgaste para os outros grupos, na medida que, para eles, a variação da energia desta banda apresenta uma dinâmica parecida com a de 5 a 6 kHz. As proposições anteriores equivalem constatar que a razão entre a energia da banda B e a energia da banda A (B/A) seguem uma relação inversamente proporcional com o valor de VB, como é possível ver nos gráficos de dispersão mostrados nas Figuras 29 a 33. A partir desta nova escolha de bandas, gerou-se novos gráficos de dispersão, mostrados nas Figuras de 24 a 28 .

Estas imagens verificam que a nova seleção de bandas foi mais adequada que a sugestão inicial. Torna-se manifesto que a visualização da relação entre as bandas de frequência do sinal e o desgaste de flanco nos diagramas de dispersão para duas bandas de frequência dos sinais de emissão acústica é clarificada. Ademais, os diagramas de dispersão da razão B/A corroboram com esta análise. Vale apontar, no entanto, que a diminuição do valor de B/A não é estritamente relacionado ao aumento de VB, como é possível reparar nas Figuras 30 e 31, as quais mostram pontos fora desta tendência global. Todavia, é seguro afirmar que tais desvios tratam-se de exceções, as quais podem ser compreendidas

Figura 11 – Exemplo de sinal no tempo do caso 11




pelas redes neurais empregadas a partir de treinamentos mais robustos.

Considerando que os resultados deste trabalho devem ser gerais para todas as condições de operação analisadas, torna-se imperativo comparar pontos de diferentes gráficos de dispersão, no intuito de tornar conferir a confiabilidade das conclusões feitas. Para tal, observa-se os gráficos de dispersão entre a razão B/A e o desgaste. O motivo norteador da escolha destes gráficos é de evitar que a energia emitida pela emissão acústica seja vista em termos de seus valores absolutos, na medida que estes são fortemente influenciados pelo material da fresa, pela sua velocidade de avanço e profundidade de corte. Ao comparar as escalas do eixo y das Figuras de 29 e 33, dá-se conta que as previsões de desgaste da fresa por uma CNN seriam prejudicadas se todas as imagens inseridas para o treinamento não fossem distinguidas entre os diferentes grupos.

Isso ressalta a limitação da aplicação de uma CNN treinada para prever o desgaste em um determinado grupo de condições de usinagem para a previsão em outro grupo. Além disso, a inserção de diferentes condições de usinagem requer um novo treinamento da CNN. No entanto, essa limitação pode ser parcialmente mitigada ao incorporar informações sobre as combinações de parâmetros das amostras utilizadas no treinamento e validação da rede. Isso se deve ao fato de que a tendência de diminuição da razão B/A com o aumento do desgaste é universal, sendo apenas o valor dessa razão variável entre os casos.

Considerando todas as discussões feitas, a Figuras 34 e 35 apresenta algumas WVD

Figura 12 – Exemplo de sinal no tempo do caso 12



filtradas nas duas bandas A e B.


A Figura 34 agrupa um conjunto de WVD's de diferentes grupos. Esta seleção de imagens, em conjunto com a WVD mostrada na Figura 35, traz um complemento para a discussão em andamento. Desta forma, a observação, na WVD da Figura 35, de um padrão no domínio tempo-frequência semelhante ao da Figura 34c, mesmo associado a um valor de desgaste consideravelmente menor, denuncia que a seleção das faixas de frequência não torna a metodologia insensível a diversas condições de fresamento. Porém, comparando as subfiguras da Figura 34, percebe-se que ainda é possível enxergar um padrão relacionado ao avanço do desgaste mesmo entre sinais de diferentes casos.

Independentemente das considerações anteriores, infere-se que o novo conjunto de bandas selecionado para filtrar os sinais de emissão acústica simplificou a análise visual das imagens geradas pelo emprego da WVD, otimizando todas as características julgadas pertinentes para extração de características dos sinais já exploradas.

Encerrando com a metodologia do estudo explicada em outras seções, seguiu-se com o treinamento de uma CNN a partir das WVD's dos sinais filtrados nas bandas A e B e produziu-se a matriz de confusão e a curva ROC, mostradas na Figura 36.

Com base nos resultados apresentados, a rede neural implementada apresenta uma performance robusta na classificação de dados inéditos, com uma acurácia de 86,36 % e

Figura 13 – Exemplo de sinal do caso 12 com comportamento anormal no tempo



uma boa capacidade discriminatória, como evidenciado pelo AUC de aproximadamente 0,893.

Figura 14 – WVD para três casos críticos do grupo 1







Figura 15 – WVD para três casos críticos do grupo 7



(a)



(b)



(c)

Figura 16 – WVD para três casos críticos do grupo 8







Figura 17 – WVD para três casos críticos do grupo 11



(a)



(b)



(c)

Figura 18 – WVD para três casos críticos do grupo 12




Figura 19 – Visualização da relação Energia da banda versus desgaste para o grupo 1




Figura 20 – Visualização da relação Energia da banda versus desgaste para o grupo 7




Figura 21 – Visualização da relação Energia da banda versus desgaste para o grupo 8




Figura 22 – Visualização da relação Energia da banda versus desgaste para o grupo 11




Figura 23 – Visualização da relação Energia da banda versus desgaste para o grupo 12




Figura 24 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 1




Figura 25 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 7




Figura 26 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 8




Figura 27 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 11




Figura 28 – Visualização, para o novo conjunto de bandas, da relação Energia da banda versus desgaste para o grupo 12




Figura 29 – Visualização, da relação entre B/A e desgaste para o grupo 1




Figura 30 – Visualização, da relação entre B/A e desgaste para o grupo 7




Figura 31 – Visualização, da relação entre B/A e desgaste para o grupo 8




Figura 32 – Visualização, da relação entre B/A e desgaste para o grupo 11




Figura 33 – Visualização, da relação entre B/A e desgaste para o grupo 12







Figura 34 – Visualização de algumas WVD's filtradas em B e A



(a) Exemplo de sinal de emissão acústica de fresa com baixo desgaste



(b) Exemplo de sinal de emissão acústica de fresa com médio desgaste



(c) Exemplo de sinal de emissão acústica de fresa com desgaste alto

Figura 35 – WVD para sinal do caso 11 correspondente a alto nível de desgaste





Figura 36 – Curvas ROC e matriz de confusão para avaliação das previsões realizadas pela rede neural treinada.



3 CONCLUSÃO

Este trabalho de conclusão de curso propõe uma avaliação robusta da aplicabilidade de representações tempo-frequência na monitoração de processos industriais, representado aqui pelo monitoramento do desgaste em ferramentas de fresamento. O objetivo principal foi estudar a viabilidade de representações tempo-frequência como ferramenta para extração de características relacionadas à condição da ferramenta no processo de fresamento, utilizando a Distribuição de Wigner-Ville (WVD), uma ferramenta pouco explorada pela literatura e inédita para esta aplicação. Adicionalmente, buscou-se contribuir para a otimização do processo de manufatura através da implementação de uma Rede Neural Convolucional (CNN) para classificar diferentes níveis de desgaste.

Através de uma metodologia rigorosa e inovadora, este trabalho atingiu seus objetivos, demonstrando que a WVD proporciona uma representação de alta resolução das características de sinais de emissão acústica, o que é crucial para a detecção precisa dos estágios de desgaste das ferramentas. O estudo revelou que, à medida que o desgaste progride, há um aumento notável na energia nas bandas de frequência mais altas, principalmente dentro da faixa de 30 a 35 kHz, em relação às bandas de frequências mais baixas, com destaque para a banda de 5 a 12 kHz. Esta descoberta reforça a hipótese de que a monitoração avançada pode efetivamente prever falhas antes que afetem a qualidade da produção.

A implementação de uma Rede Neural Convolucional para classificar esses estados de desgaste representou um passo fundamental no sentido de aplicar aprendizado de máquina em tempo real na manufatura. A rede foi capaz de diferenciar com sucesso entre diferentes condições de desgaste com uma precisão notável, sugerindo que modelos de aprendizado profundo podem ser integrados em sistemas de manufatura para uma resposta automática e informada a mudanças no estado da ferramenta.

Além disso, o estudo explorou a redução do custo computacional através de métodos de pré-processamento eficazes, que permitiram a análise de grandes conjuntos de dados, com uma redução de até 73 % do seu tamanho original, sem comprometer a integridade das características extraídas. Este aspecto é particularmente valioso para a implementação industrial, onde o volume de dados e a necessidade de processamento em tempo real impõem desafios significativos. A aplicação da metodologia da diminuição da frequência de amostragem para redução do custo computacional mostrou-se eficaz, mantendo a resolução e precisão das análises.

Este trabalho, portanto, não apenas alcançou seus objetivos, mas também estabeleceu uma base sólida para futuras inovações na área de manufatura inteligente, destacando

o potencial para aprimoramentos na manutenção preditiva e na eficiência operacional em ambientes de Indústria 4.0.

REFERÊNCIAS

- ADDISON, P. S. Wavelet transforms and the ecg: a review. **Physiological measurement**, IOP Publishing, v. 26, n. 5, p. R155, 2005.
- AGHAZADEH, F.; TAHAN, A.; THOMAS, M. Tool condition monitoring using spectral subtraction and convolutional neural networks in milling process. **The International Journal of Advanced Manufacturing Technology**, v. 98, n. 9–12, p. 3217–3227, October 2018. Disponível em: <http://link.springer.com/10.1007/s00170-018-2420-0>.
- AHUETT-GARZA, H.; KURFESS, T. R. A brief discussion on the trends of habilitating technologies for industry 4.0 and smart manufacturing. **Manufacturing letters**, v. 15, p. 60–63, 2018. Disponível em: <https://api.semanticscholar.org/CorpusID:116293420>.
- AROKIADASS, R.; PALANIRADJA, K.; ALAGUMOORTHY, N. Prediction and optimization of end milling process parameters of cast aluminium based mmc. **Transactions of Nonferrous Metals Society of China**, Elsevier, v. 22, n. 7, p. 1568–1574, 2012.
- ATTANASIO, A.; FAINI, F.; OUTEIRO, J. C. Fem simulation of tool wear in drilling. *In*: . [S.l.: s.n.]: Elsevier B.V., 2017. v. 58, p. 440–444. ISSN 22128271.
- BARREIRO, J. *et al.* Tcm system in contour milling of very thick-very large steel plates based on vibration and ae signals. **Journal of Materials Processing Technology**, Elsevier Ltd, v. 246, p. 144–157, 8 2017. ISSN 09240136.
- BHUIYAN, M.; CHOUDHURY, I.; DAHARI, M. Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning. **Journal of Manufacturing Systems**, Elsevier, v. 33, n. 4, p. 476–487, 2014.
- CALABRIA, R. **ANÁLISE DO DESEMPENHO DAS FERRAMENTAS DE METAL DURO E METAL DURO POLIDO NO PROCESSO DE FRESAMENTO DE ALUMÍNIO**. 2014. Trabalho de Conclusão de Curso, Universidade de Caxias do Sul. Disponível em: <https://repositorio.ucs.br/xmlui/bitstream/handle/11338/1962/TCC%20Rafael%20Calabria.pdf?sequence=1&isAllowed=y>.
- CHEN, Y.; JIN, Y.; JIRI, G. Predicting tool wear with multi-sensor data using deep belief networks. **International Journal of Advanced Manufacturing Technology**, Springer London, v. 99, p. 1917–1926, 11 2018. ISSN 14333015.
- CINAR, Z. M. *et al.* Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. **Sustainability**, v. 12, n. 19, p. 8211, October 2020. Disponível em: <https://www.mdpi.com/2071-1050/12/19/8211>.
- DING, H. *et al.* State of ai-based monitoring in smart manufacturing and introduction to focused section. **IEEE/ASME Transactions on Mechatronics**, v. 25, n. 5, p. 2143–2154, October 2020. Disponível em: <https://ieeexplore.ieee.org/document/9189823>.
- DINIZ, A. E.; SINATORA, A.; BIANCHI, E. C. Monitoring of tool wear in drilling using acoustic emission signals and neural networks. **Journal of Materials Processing Technology**, Elsevier, v. 146, n. 2, p. 244–250, 2004.

DUO, A. *et al.* Drilling process monitoring: a framework for data gathering and feature extraction techniques. **Procedia CIRP**, Elsevier, v. 99, p. 189–195, 2021.

FACELI, K. *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. [S.l.: s.n.]: LTC, 2021.

GERON, U. **Hands-on machine learning with scikit-learn, keras, and tensorflow: concepts, tools, and techniques to build intelligent systems**. [S.l.: s.n.]: O'Reilly Media, Inc, 2019.

GOEBEL, A. A. K. Documentation for mill data set. **NASA Ames Research Center**, 2007.

GU, J. *et al.* Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, May 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0031320317304120>.

HAYKIN, S. **Neural networks and learning machines**. [S.l.: s.n.]: Prentice Hall Pearson, 2009.

HUANG, Z. *et al.* Tool wear predicting based on multi-domain feature fusion by deep convolutional neural network in milling operations. **Journal of Intelligent Manufacturing**, Springer, v. 31, p. 953–966, 4 2020. ISSN 15728145.

HUANG, Z. *et al.* Tool wear monitoring with vibration signals based on short-time fourier transform and deep convolutional neural network in milling. **Mathematical Problems in Engineering**, v. 2021, p. 1–14, June 2021. Disponível em: <https://www.hindawi.com/journals/mpe/2021/9976939/>.

KUNTOĞLU, M.; SAĞLAM, H. Anova and fuzzy rule based evaluation and estimation of flank wear, temperature and acoustic emission in turning. **CIRP Journal of Manufacturing Science and Technology**, Elsevier, v. 35, p. 589–603, 2021.

LI, H. *et al.* Tool wear and hole quality investigation in dry helical milling of ti-6al-4v alloy. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 71, p. 1511–1523, 2014.

LI, X. *et al.* Systematic review on tool breakage monitoring techniques in machining operations. **International Journal of Machine Tools and Manufacture**, Elsevier, v. 176, p. 103882, 2022.

LI, X.; OUYANG, G.; LIANG, Z. Complexity measure of motor current signals for tool flute breakage detection in end milling. **International Journal of Machine Tools and Manufacture**, Elsevier, v. 48, n. 3-4, p. 371–379, 2008.

LI, Y. *et al.* Tool wear prediction with external signals based on lightweight deep learning model. **IEEE Access**, IEEE, v. 7, p. 123456–123465, 2019.

LI, Z. *et al.* A survey of convolutional neural networks: Analysis, applications, and prospects. **IEEE Transactions on Neural Networks and Learning Systems**, v. 33, n. 12, p. 6999–7019, December 2022. Disponível em: <https://ieeexplore.ieee.org/document/9451544>.

- LINS, R. G.; GIVIGI, S. N. Cooperative robotics and machine learning for smart manufacturing: Platform design and trends within the context of industrial internet of things. **IEEE Access**, v. 9, p. 95444–95455, 2021.
- MARTIN, W.; FLANDRIN, P. Wigner-ville spectral analysis of nonstationary processes. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 33, n. 6, p. 1461–1470, 1985.
- MOHANRAJ, T. *et al.* Development of tool condition monitoring system in end milling process using wavelet features and hoelder's exponent with machine learning algorithms. **Measurement: Journal of the International Measurement Confederation**, Elsevier B.V., v. 173, 3 2021. ISSN 02632241.
- MONSONE, C.; CSAPÓ, B. Charting the state-of-the-art in the application of convolutional neural networks to quality control in industry 4.0 and smart manufacturing. *In: 2019 10th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*. [S.l.: s.n.], 2019. p. 463–468.
- NESLUŠAN, M. *et al.* Detection of tool breakage during hard turning through acoustic emission at low removal rates. **Measurement**, Elsevier, v. 70, p. 1–13, 2015.
- OLUFAYO, O.; ABOU-EL-HOSSEIN, K. Tool life estimation based on acoustic emission monitoring in end-milling of h13 mould-steel. **International Journal of Advanced Manufacturing Technology**, Springer London, v. 81, p. 39–51, 10 2015. ISSN 14333015.
- PAN, T. *et al.* Tool breakage monitoring based on the feature fusion of spindle acceleration signal. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 117, n. 9-10, p. 2973–2986, 2021.
- PANG, B. *et al.* Real-time monitoring of tool wear in high-speed milling of aircraft structural parts. *In: 2019 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE)*. [S.l.: s.n.], 2019. p. 761–767.
- PERES, R. S. *et al.* Industrial artificial intelligence in industry 4.0 - systematic review, challenges and outlook. **IEEE Access**, v. 8, p. 220121–220139, 2020.
- RAI, R. *et al.* Machine learning in manufacturing and industry 4.0 applications. **International Journal of Production Research**, v. 59, n. 16, p. 4773–4778, August 2021. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/00207543.2021.1956675>.
- REÑONES, A.; RODRÍGUEZ, J.; MIGUEL, L. J. de. Industrial application of a multitooth tool breakage detection system using spindle motor electrical power consumption. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 46, p. 517–528, 2010.
- SALGADO, D. R.; ALONSO, F. J. An approach based on current and sound signals for in-process tool wear monitoring. **International Journal of Machine Tools and Manufacture**, v. 47, p. 2140–2152, 11 2007. ISSN 08906955.
- SCHOLL, S. Fourier, gabor, morlet or wigner: Comparison of time-frequency transforms. 2021. Disponível em: <http://arxiv.org/abs/2101.06707>.

SERIN, G. *et al.* Review of tool condition monitoring in machining and opportunities for deep learning. **The International Journal of Advanced Manufacturing Technology**, v. 109, n. 3–4, p. 953–974, July 2020. Disponível em: <https://link.springer.com/10.1007/s00170-020-05449-w>.

SHEN, Y. *et al.* Predicting tool wear size across multi-cutting conditions using advanced machine learning techniques. **Journal of Intelligent Manufacturing**, Springer, v. 32, p. 1753–1766, 2021.

SOUTO, U. B. **Monitoramento do desgaste de ferramenta no processo de fresamento via emissão acústica**. 2007. Doutorado, Uberlândia, 2007. Disponível em: <http://repositorio.ufu.br/handle/123456789/27>.

STASZEWSKI K. WORDEN, G. T. W. Time–frequency analysis in gearbox fault detection using the wigner–ville distribution and pattern recognition. *In: Mechanical Systems and Signal Processing*. [S.l.: s.n.], 1997. v. 11, p. 673–692.

SUN, S.; HU, X.; ZHANG, W. Detection of tool breakage during milling process through acoustic emission. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 109, p. 1409–1418, 2020.

TRENT, E. M.; WRIGHT, P. K. **Metal Cutting**. Woburn: Butterworth-Heinemann, 2000. 446 p. ISBN 978-0-7506-7069-2.

WANG, G. *et al.* A new tool wear monitoring method based on multi-scale pca. **Journal of Intelligent Manufacturing**, Springer, v. 30, p. 113–122, 2019.

WANG, T. O. Z. Imaging Time-Series to Improve Classification and Imputation. 2015.

WANG, Z.; OATES, T. Imaging time-series to improve classification and imputation. **arXiv preprint arXiv:1506.00327**, May 2015. Disponível em: <http://arxiv.org/abs/1506.00327>.

WOSCHANK, M.; RAUCH, E.; ZSIFKOVITS, H. A review of further directions for artificial intelligence, machine learning, and deep learning in smart logistics. **Sustainability**, v. 12, n. 9, p. 3760, May 2020. Disponível em: <https://www.mdpi.com/2071-1050/12/9/3760>.

XIE, Z.; LI, J.; LU, Y. Feature selection and a method to improve the performance of tool condition monitoring. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 100, p. 3197–3206, 2019.

YANG, B. *et al.* Vibration singularity analysis for milling tool condition monitoring. **International Journal of Mechanical Sciences**, Elsevier, v. 166, p. 105254, 2020.

ZHOU, Y.; XUE, W. Review of tool condition monitoring methods in milling processes. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 96, p. 2509–2523, 2018.