

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**FACULDADE DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Matheus Augusto Malta Ferreira**

**Classificação Multiclasse Baseada em Séries Temporais Multivariadas do  
Estágio de Operação de Ferramentas de Corte de Torno**

Juiz de Fora

2022

**Matheus Augusto Malta Ferreira**

**Classificação Multiclasse Baseada em Séries Temporais Multivariadas do  
Estágio de Operação de Ferramentas de Corte de Torno**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Orientador: Prof. Dr. Eduardo Pestana de Aguiar

Juiz de Fora

2022

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF  
com os dados fornecidos pelo(a) autor(a)

Ferreira, Matheus Augusto Malta.

Classificação Multiclasse Baseada em Séries Temporais Multivariadas  
do Estágio de Operação de Ferramentas de Corte de Torno / Matheus  
Augusto Malta Ferreira. – 2022.

68 f. : il.

Orientador: Eduardo Pestana de Aguiar

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Faculdade  
de Engenharia. Programa de Pós-graduação em Engenharia Elétrica, 2022.

1. Inteligência Computacional. 2. Processamento de Sinais. 3. Análise  
de Dados. I. Aguiar, Eduardo Pestana de, orient.

**Matheus Augusto Malta Ferreira**

**Classificação Multiclasse Baseada em Séries Temporais Multivariadas do Estágio de  
Operação de Ferramentas de Corte de Torno**

Dissertação  
apresentada ao  
Programa de Pós-  
Graduação em  
Engenharia  
Elétrica da Universidade  
Federal de Juiz de  
Fora como requisito  
parcial à obtenção do  
título de Mestre em  
Engenharia Elétrica.  
Área de  
concentração:  
Sistemas Eletrônicos

Aprovada em 07 de março de 2023.

**BANCA EXAMINADORA**

**Prof. Dr. Eduardo Pestana de Aguiar** - Orientador

Universidade Federal de Juiz de Fora

**Prof. Dr. Carmelo José Albanez Bastos Filho**

Universidade Federal de Pernambuco

**Prof. Dr. Moisés Vidal Ribeiro**

Universidade Federal de Juiz de Fora

Juiz de Fora, 28/02/2023.



Documento assinado eletronicamente por **CARMELO JOSE ALBANEZ BASTOS**



**FILHO, Usuário Externo**, em 07/03/2023, às 16:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Eduardo Pestana de Aguiar, Professor(a)**, em 09/03/2023, às 13:11, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Moises Vidal Ribeiro, Professor(a)**, em 16/03/2023, às 11:34, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf ([www2.ufjf.br/SEI](http://www2.ufjf.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **1164709** e o código CRC **30BEACAD**.

---

## AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Marcelo e Lea. Minhas irmãs, Karla e Patrícia. Minha família e amigos que estiveram comigo durante essa caminhada.

Agradeço a todo o time do LAIIC (Laboratório de Automação Industrial e Inteligência Computacional), em especial ao Thiago Esterici, Marcos Victor e Guilherme Miranda que foram fundamentais no desenvolvimento desse trabalho.

Agradeço ao meu orientador, Professor Eduardo Pestana de Aguiar, por todo ensinamento, atenção e confiança depositada no meu trabalho.

Gostaria de agradecer também à todos os professores que me ajudaram durante essa jornada e também à banca por toda a disponibilidade e desde já agradeço a contribuição prestada no objetivo de engrandecer esse trabalho.

Também agradeço ao SESI/SENAI Juiz de Fora UI Luiz Adelar Scheuer pela colaboração e hospitalidade nas suas instalações durante o processo de aquisição de dados.

E finalmente, também gostaria de agradecer a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Processo 433389 / 2018-4, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) - APQ-02922-18 e Universidade Federal de Juiz de Fora (UFJF) pelo suporte financeiro.

## RESUMO

Grande parte dos componentes mecânicos fabricados para uso industrial sofrem algum processo de usinagem durante a sua fabricação. Portanto, processos de manufatura executados com ferramentas em condições inadequadas de operação apresentam uma alta probabilidade de sofrer interrupções inesperadas, acidentes, baixa qualidade no produto fabricado e perdas econômicas. Conseqüentemente, a possibilidade de classificar iminências de falha pode resultar em redução de custos, aumento de produtividade e uma maior segurança para os operadores das máquinas. Esse trabalho apresenta um protótipo de baixo custo para aquisição de dados e um modelo de inteligência computacional baseado em processamento digital de sinais, no algoritmo de particionamento de dados Auto-Organizável Ciente de Direção (SODA - Self-Organised Direction Aware) e técnicas de aprendizagem de máquina, incluindo Extração de Atributos de Series Temporais baseado em testes de Hipóteses Escalonáveis (TSFRESH - Time Series Feature Extraction based on Scalable Hypothesis tests) e Análise de Componentes Principais (PCA - Principal Components Analysis), para resolver esse problema. Considerando uma aplicação do modelo em tempo real, a análise da relevância e seleção dos atributos se torna imprescindível pela capacidade de reduzir a dimensionalidade das séries temporais observadas. O modelo proposto nesse trabalho é capaz de identificar os padrões que diferenciam o desgaste de flanco de uma ferramenta de corte em um cenário multiclasse como ferramenta em estágio adequado, intermediário e inadequado, alcançando resultados satisfatórios em todos os casos e permitindo a prevenção de falhas.

Palavras-chave: Inteligência Computacional. Processamento de Sinais. Análise de Dados.

## ABSTRACT

The majority of mechanical components went through a machining process during their manufacturing. Therefore, manufacturing processes with inadequate condition tools are likely to induce unexpected operational interruptions, accidents, product quality, and economic losses. Accordingly, the ability to classify fault imminences can result in cost reduction, along with productivity and safety increase. This work presents a low-cost data acquisition system and aims to discuss a model based on digital signal processing, the Self-Organised Direction Aware Data Partitioning Algorithm (SODA) and machine learning techniques, including time series Feature Extraction based on Scalable Hypothesis tests (TSFRESH) and Principal Components Analysis (PCA), to solve this problem. Taking into consideration the real-time monitoring, features selection and features relevance analysis are essential as it can lead to a dimensionality and data flow rate reduction. The model proposed in this work can identify the patterns that distinguish the cutting tool's flank wear in a multi-class scenario as adequate, intermediate, and inadequate conditions, achieving satisfactory performances in all cases and allowing to prevent fault occurrences.

Keywords: Machine Learning. Signal Processing. Data Analysis.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Evolução do Desgaste de Flanco na Ferramenta . . . . .	23
Figura 2 - Centro de Torneamento Romi GL280M 2014 com CNC da FANUC. . . . .	24
Figura 3 - Fluxo de Aquisição do Protótipo. . . . .	26
Figura 4 - Diagrama do Algoritmo do STM32F407ZGT6. . . . .	26
Figura 5 - Sistema de Aquisição de Dados. . . . .	27
Figura 6 - Modelo Proposto . . . . .	31
Figura 7 - Exemplos de Atributos Extraídos pelo TSFRESH. . . . .	33
Figura 8 - Descrição Detalhada do TSFRESH Multiclasse. . . . .	35
Figura 9 - Exemplo ilustrativo PCA. . . . .	37
Figura 10 - Evolução do Desgaste de Flanco na Ferramenta . . . . .	43
Figura 11 - Componente Senoidal de 60Hz. . . . .	44
Figura 12 - Componente Senoidal de 60 Hz com Adição da Componente de 6 kHz. . . . .	44
Figura 13 - Componente Senoidal de 60 Hz com Adição da Componente de 6 kHz e Ruído Gaussiano Branco. . . . .	45
Figura 14 - Média do Processo Senoidal. . . . .	45
Figura 15 - Autocorrelação do Processo Senoidal. . . . .	46
Figura 16 - Autocorrelação do Processo Senoidal - 100 atrasos. . . . .	46
Figura 17 - Média do Processo Real - Ferramenta Adequada. . . . .	48
Figura 18 - Média do Processo Real - Ferramenta Intermediária. . . . .	48
Figura 19 - Média do Processo Real - Ferramenta Inadequada. . . . .	49
Figura 20 - Autocorrelação do Processo Real - Ferramenta Adequada. . . . .	50
Figura 21 - Autocorrelação do Processo Real - Ferramenta Intermediária. . . . .	50
Figura 22 - Autocorrelação do Processo Real - Ferramenta Inadequada. . . . .	51
Figura 23 - Autocorrelação do Processo Real - Ferramenta Adequada. . . . .	51
Figura 24 - Autocorrelação do Processo Real - Ferramenta Intermediária. . . . .	52
Figura 25 - Autocorrelação do Processo Real - Ferramenta Inadequada. . . . .	52
Figura 26 - Função de Autocorrelação para 5 Realizações do Processo - Ferramenta Adequada. . . . .	54
Figura 27 - Função de Autocorrelação para 5 Realizações do Processo - Ferramenta Intermediária. . . . .	54
Figura 28 - Função de Autocorrelação para 5 Realizações do Processo - Ferramenta Inadequada. . . . .	55
Figura 29 - Densidade Espectral de Potência - Ferramenta Adequada . . . . .	56
Figura 30 - Densidade Espectral de Potência - Ferramenta Intermediária. . . . .	57
Figura 31 - Densidade Espectral de Potência - Ferramenta Inadequada. . . . .	57
Figura 32 - Diagrama de Bode do Filtro Butterworth passa baixa de segunda ordem	58

Figura 33 - Matriz de Confusão para o Classificador *MLP Neural Network* utilizando a interseção dos atributos selecionados . . . . . 60

## LISTA DE TABELAS

Tabela 1 – Representação da Entrada de Dados do Modelo. . . . .	42
Tabela 2 – Descritivo do Procedimento de Aquisição de Dados. . . . .	43
Tabela 3 – Acurácia dos Classificadores . . . . .	59

## LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i>
AWGN	<i>Additive White Gaussian Noise</i>
CBM	<i>Condition Based Maintenance</i>
CDF	<i>Cumulative Distribution Function</i>
CNN	<i>Convolutional Neural Network</i>
DA	<i>Direction Aware</i>
DBN	<i>Deep Belief Network</i>
EDA	<i>Empirical Data Analytics</i>
EDM	<i>Electrical Discharge Machining</i>
FFT	<i>Fast Fourier Transform</i>
FSM	<i>Finite State Machine</i>
GPR	<i>Gaussian Process Regressor</i>
HMM	<i>Hidden Markov Model</i>
ISO	<i>International Organization for Standardization</i>
KS	Kolmogorov-Smirnov
LAIC	Laboratório de Automação Industrial e Inteligência Computacional
LSTM	<i>Long Short-term Memory</i>
MLP	<i>Multilayer Perceptron</i>
MQL	<i>Minimum Quantity Lubrication</i>
NN	<i>Neural Network</i>
PCs	<i>Principal Components</i>
PCA	<i>Principal Components Analysis</i>
PDF	<i>Probability Density Function</i>
PNN	<i>Probabilistic Neural Network</i>
RBF	<i>Radial Basis Function</i>
SODA	<i>Self-Organized Direction Aware Data Partitioning Algorithm</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
TSFRESH	<i>Time Series Feature Extraction Based on Escalable Hypothesis Tests</i>
UFJF	Universidade Federal de Juiz de Fora
WSS	<i>Wide Sense Stationary</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>13</b>
1.1	REVISÃO BIBLIOGRÁFICA . . . . .	16
1.2	OBJETIVOS . . . . .	18
1.3	CONTRIBUIÇÕES . . . . .	19
1.4	ORGANIZAÇÃO DO TRABALHO . . . . .	20
1.5	PUBLICAÇÕES . . . . .	20
<b>2</b>	<b>FORMULAÇÃO DO PROBLEMA . . . . .</b>	<b>22</b>
<b>3</b>	<b>SISTEMA DE AQUISIÇÃO E CLASSIFICAÇÃO MULTICLASSE DE SÉRIES TEMPORAIS MULTIVARIADAS . . . . .</b>	<b>25</b>
3.1	SISTEMA DE AQUISIÇÃO DE DADOS . . . . .	25
3.2	CARACTERIZAÇÃO DO PROCESSO ESTOCÁSTICO . . . . .	27
<b>3.2.1</b>	<b>Ferramentas de Caracterização . . . . .</b>	<b>28</b>
3.2.1.1	<i>Média . . . . .</i>	28
3.2.1.2	<i>Autocorrelação . . . . .</i>	29
3.2.1.3	<i>Densidade Espectral de Potência . . . . .</i>	29
<b>3.2.2</b>	<b>Caracterizações . . . . .</b>	<b>30</b>
3.2.2.1	<i>Estacionariedade . . . . .</i>	30
3.2.2.2	<i>Ergodicidade . . . . .</i>	30
3.3	MODELO DE CLASSIFICAÇÃO MULTICLASSE DE SÉRIES TEMPORAIS MULTIVARIADAS . . . . .	30
<b>3.3.1</b>	<b>Filtragem . . . . .</b>	<b>32</b>
<b>3.3.2</b>	<b>Normalização . . . . .</b>	<b>32</b>
<b>3.3.3</b>	<b>Extração de Atributos Baseada em Testes de Hipóteses Escalonáveis (TSFRESH) . . . . .</b>	<b>32</b>
<b>3.3.4</b>	<b>Análise de Componentes Principais (PCA) . . . . .</b>	<b>35</b>
<b>3.3.5</b>	<b>Algoritmo de Particionamento de Dados Auto-organizável Ciente de Direção (SODA) . . . . .</b>	<b>37</b>
3.3.5.1	<i>Componentes de distância/dissimilaridade . . . . .</i>	38
3.3.5.2	<i>Operadores EDA . . . . .</i>	38
3.3.5.3	<i>Algoritmo SODA para particionamento de dados . . . . .</i>	39
<b>3.3.6</b>	<b>Algoritmo de Agrupamento . . . . .</b>	<b>40</b>
<b>4</b>	<b>RESULTADOS . . . . .</b>	<b>42</b>
4.1	BASE DE DADOS . . . . .	42
4.2	ANÁLISE DO PROCESSO ESTOCÁSTICO . . . . .	44
<b>4.2.1</b>	<b>Simplificação Matemática . . . . .</b>	<b>44</b>
4.2.1.1	<i>Média . . . . .</i>	45
4.2.1.2	<i>Autocorrelação . . . . .</i>	45

<b>4.2.2</b>	<b>Processo Aquisitado do Motor do Torno . . . . .</b>	<b>46</b>
<i>4.2.2.1</i>	<i>Média . . . . .</i>	<i>47</i>
<i>4.2.2.2</i>	<i>Autocorrelação . . . . .</i>	<i>49</i>
<i>4.2.2.3</i>	<i>Ergodicidade . . . . .</i>	<i>53</i>
<i>4.2.2.4</i>	<i>Densidade Espectral de Potência . . . . .</i>	<i>55</i>
<b>4.3</b>	<b>CLASSIFICAÇÃO . . . . .</b>	<b>58</b>
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>61</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>63</b>

## 1 INTRODUÇÃO

Uma pesquisa sobre o mercado mundial ferramentas de corte em 2020 publicada pela Gardner Business Media (1) mostra uma queda no consumo e produção de ferramentas de corte comparado com anos anteriores. A pandemia do coronavírus e o lockdown em diversos países causaram um impacto significativo no mercado de ferramentas de corte.

O consumo global de ferramentas de corte em 2020 foi de US\$66,8 bilhões, uma queda de 20,1% comparando 2019. Entretanto, se levarmos em consideração a queda no consumo de ferramentas de corte durante a crise econômica de 2008/09, os efeitos da pandemia no mercado de ferramentas de corte não foram tão severos como esperado tendo em vista a queda de 34,8% que foi observada em 2009 (2).

No entanto, os mercados de bens primários e intermediários, como componentes automotivos, eletrônicos e bens duráveis, tendem a se recuperar. Considerando que maior parte da demanda por ferramentas de corte vem desses fabricantes, espera-se um crescimento no consumo de ferramentas de corte para os próximos anos. Nesse cenário, a crescente competitividade leva as empresas a exigirem redução no consumo de ferramentas, tempo de manutenção e melhorias na qualidade, disponibilidade e confiabilidade dos processos de fabricação. Conseqüentemente, manutenção baseada em condição (CBM - *Condition Based Maintenance*) (3, 4), tem sido amplamente aplicada na fabricação e é uma das aplicações mais efetivas de manutenção preditiva, devido a seu sucesso em reduzir a incerteza envolvendo as atividades de manutenção (5). Nesse contexto, este trabalho é essencial, já que integra monitoramento de dados em tempo real ao processo de usinagem.

De acordo com Trent e Wright (6), aproximadamente 10% da produção de metal no mundo é submetida a um processo de usinagem e com isso emprega milhões de pessoas no mundo. Além do mais, esse processo de fabricação é de vital importância, dado que grande maioria dos componentes mecânicos fabricados para uso industrial sofreu algum processo de usinagem durante sua fabricação. Conseqüentemente, o desenvolvimento de novas tecnologias nessa área terá um enorme impacto econômico e social na quarta revolução industrial.

O desenvolvimento de sistemas capazes de supervisionar os processos de usinagem com monitoramento em tempo real ganharam força, assim como as abordagens que diminuem a interferência humana no processo (7) Além do mais, manutenção preditiva permite evitar falhas, prevenir acidentes e reduzir perdas econômicas. A adoção de técnicas de aprendizagem de máquina autônomas, ou seja, que não requerem um conhecimento prévio do usuário ou um elevado número de hiperparâmetros, esses sistemas são projetados para serem capazes de aprender a partir de dados, sem a necessidade de programação explícita. Os sistemas devem ser capazes de tomar decisões em tempo real com base em informações de sensores. Um exemplo é a análises de séries temporais que por meio de

extração e seleção de atributos pode ser útil para melhorar a confiabilidade do processo de usinagem (8), assim como reduzir o tempo de manutenção, o que leva a uma diminuição de custos.

Mesmo com a literatura apresentando diversos métodos para diagnóstico de falhas (9), aplicações de aprendizado autônomo para classificação de ferramentas de corte de torneamento apresentam um potencial inexplorado. Portanto, com o objetivo de desenvolver um modelo capaz de trabalhar em CBM, uma abordagem com análises de séries temporais foi adotada nesse trabalho, devido tanto à crescente importância nos sistemas de controle e previsão quanto à capacidade de informação relevante nas séries temporais e a forma com que a mudança nos padrões causa variação em seu comportamento (10).

Séries temporais são utilizadas em vários campos para entender e analisar a evolução de um fenômeno ao longo do tempo. Exemplos de tais conjuntos de dados são numerosos, como por exemplo, fechamento diário de preços de ações, sinais de áudio e eletrocardiograma (11). A característica fundamental de uma série temporal é que suas observações são correlacionadas. Quando o número de variáveis observadas para um mesmo processo é maior que um, as séries são chamadas de séries temporais multivariadas (12).

Em relação às séries temporais, uma importante característica a ser levada em consideração é a alta dimensionalidade dos dados, que se deve tanto ao tamanho das séries quanto à presença de várias séries em paralelo. Cada observação em uma série temporal é representada por um ponto de dados que pode incluir várias dimensões ou características, como dados de diferentes sensores em um mesmo sistema. Quanto maior o número de dimensões, maior será a complexidade do conjunto de dados. Além disso, a modelagem multivariada pode ser usada para lidar com várias séries em paralelo, buscando relacionamentos entre elas e permitindo análises mais completas dos dados. Logo, a sua análise se torna bem difícil para diversos algoritmos, especialmente quando o tempo de execução é levado em consideração. Além disso, mineração de dados geralmente requer alto custo computacional quando aplicado a um grande volume de dados. Assim a redução da dimensionalidade dos dados através da extração de atributos se torna alternativa para ajudar a reduzir o tempo e custo computacional na análise de dados de séries temporais, já que a extração e seleção de atributos permite trabalhar com conjuntos de dados menores e mais simples, permite melhorar a precisão dos modelos de previsão de séries temporais, pois a redução de dimensionalidade ajuda a eliminar características irrelevantes e redundantes, aumentando a relevância das informações mais importantes.

Por outro lado, um dos maiores desafios quando é adotada uma análise de séries temporais é selecionar atributos pertinentes para representar os dados já que a escolha de quais atributos devem ser extraídos ou selecionados pode ser subjetiva, o que pode levar a resultados diferentes dependendo do analista ou método utilizado e também a extração e seleção de atributos pode excluir informações relevantes. Considerando essas dificuldades,

uma metodologia chamada Extração de Atributos de Séries Temporais baseado em testes de Hipóteses Escalonáveis (TSFRESH - *Time Series Feature Extraction based on Scalable Hypothesis tests*) (13) foi adotada como solução nesse trabalho. O TSFRESH, quando o assunto é extração de atributos, soluciona o problema da alta dinamicidade da informação relacionada à uma análise de séries temporais. Adicionalmente a seleção de atributos por teste de hipóteses proveniente do TSFRESH reduz a dimensionalidade dos dados.

A escolha do TSFRESH se deve ao fato de ser uma biblioteca projetada para ser rápido e escalável, permitindo a extração e seleção de atributos em grandes conjuntos de dados de séries temporais, por utilizar testes de hipótese estatística para selecionar automaticamente os atributos mais relevantes para uma determinada tarefa de análise de séries temporais, eliminando a subjetividade na escolha de atributos e também por extrair um elevado número de atributos de séries temporais, incluindo características de tendência, sazonalidade, autocorrelação, entropia, entre outras, o que pode levar a uma melhor compreensão dos dados e a modelos mais precisos.

A seleção de atributos utilizada pelo TSFRESH é feita utilizando o Teste de Kolmogorov-Smirnov (KS) (14). O teste KS é feito calculando a maior diferença entre as funções de distribuição acumulada (CDF - *Cumulative Distribution Function*) de duas variáveis aleatórias. Logo, o teste KS foi desenhado para problemas de classificação binários. Como o TSFRESH é visto na literatura sendo aplicado em diversos modelos para classificação de falhas, a implementação desse método em um cenário multiclasse apresenta um potencial inexplorado. Neste trabalho é proposto uma versão aprimorada do TSFRESH para o cenário multiclasse.

Em conjunto com o TSFRESH, a fim de reduzir a dimensionalidade dos dados, o método Análise de Componentes Principais (PCA - *Principal Component Analysis*) (15) foi aplicado. O PCA é um método utilizado para reduzir a dimensionalidade do problema em componentes não correlacionadas que são combinações lineares das variáveis originais. Por meio do cálculo de componentes principais, o PCA proporciona a capacidade de manter a informação dos atributos provenientes da seleção de atributos do TSFRESH em um número reduzido de componentes mantendo uma parcela da variância dos dados. As componentes principais geradas pelo PCA são combinações lineares dos atributos originais, o que torna fácil interpretar o significado das variáveis resultantes, ao mesmo tempo torna o PCA é menos sensível a ruídos em comparação com outras técnicas de redução de dimensionalidade.

Com o objetivo diminuir a interferência humana no processo, o algoritmo de particionamento de dados Auto-Organizável Ciente de Direção (SODA - *Self-Organised Direction Aware*) foi adotado nesse trabalho. Os autores em (16) demonstraram que mesmo sendo considerado uma forma não supervisionada de aprendizado de máquina, técnicas de classificação tradicionais requerem um conhecimento pré-existente para as modelar e

operar, o que leva a resultados dependentes do usuário. É importante enfatizar que o algoritmo SODA apresenta uma alta capacidade de se adaptar a múltiplos padrões de dados, assim como uma extensão para o processamento de dados transmitidos em tempo real, o que permite um aprimoramento futuro deste trabalho para um modelo adaptativo para prognóstico de falhas.

O SODA provê um modelo de particionamento de dados não paramétrico, livre de suposições e totalmente baseado no padrão dos dados (17, 18, 19). Se difere de teorias tradicionais de probabilidade, estatística e algoritmos de aprendizado, por se tratar exclusivamente de observações dos dados sem a necessidade de suposições antecedentes (16, 20). Consequentemente, as nuvens de dados do SODA são não paramétricas e seu formato não é delimitado pelo tipo de métrica de distância utilizada, já que elas representam diretamente as propriedades de um conjunto local em relação à todas as amostras de dados observadas (16).

O SODA pode se ajustar continuamente a cada iteração, permitindo ao algoritmo seguir as mudanças nos padrões dos dados que são transmitidos. Assim, essa evolução no modelo permite que o SODA tenha uma alta capacidade de se adaptar a múltiplos tipos de dados, assim como a sua extensão para o processamento dos dados em tempo real.

## 1.1 REVISÃO BIBLIOGRÁFICA

Levando em consideração a substituição de ferramentas de corte, as mudanças começaram quando a implementação de mecanismos de inspeção adaptativa permitiu que o procedimento de substituição baseado no monitoramento do desgaste de flanco crescesse (21). Contudo, esse tipo de procedimento não é aplicável devido ao grande número de variáveis envolvidas (material da peça, material da ferramenta, processo de usinagem, condições de corte, ambiente de fabricação, forças, temperatura, fluido de corte, etc.) o que torna esse tipo de tecnologia cara e subjetiva.

Os autores em (22) propuseram um modelo que obtêm as características essenciais do sistema de alimentação de um servo motor DC e estudaram a acurácia no cálculo da força de corte no processo de torneamento através da corrente do motor. Altintas (23, 24) investigou a possibilidade de usar a corrente induzida como um sensor para aferir a força de corte. Chang (25) implementou técnicas neuro-fuzzy para estimar a força de corte pela corrente de alimentação do motor de giro do torno. Lee et al. (26, 27) utilizando um dinamômetro concluiu que a sensibilidade da corrente de alimentação do motor é o suficiente para caracterizar a quebra da ferramenta.

Os autores em (28) treinaram uma rede neural (NN - *Neural Network*) perceptron multicamadas (MLP - *Multi-Layer Perceptron*) para predição da rugosidade do material. Özel et al. (29) concluiu que modelos utilizando NN são capazes de identificar os padrões referentes a rugosidade da superfície, condições de corte e desgaste da ferramenta. Em

(30) foi proposto um modelo utilizando processo de regressão Gaussiana (GPR - *Gaussian Process Regression*) para otimizar a taxa de remoção de material e rugosidade da superfície em processo de usinagem por descarga elétrica (EDM - *Electrical Discharge Machining*). Assarzadeh and Ghoreishi (31) buscaram otimizar o modelo de rugosidade da superfície em EDM empregando NN. Em Hossain et al. (32), uma rede neural artificial (ANN - *Artificial Neural Network*) foi apresentada para investigar e prever a relação entre os parâmetros de corte e a rugosidade da superfície em fresagem de alta velocidade. Çaydaş and Hasçahk (33) apresentaram um estudo utilizando ANN e um modelo de regressão aplicado à previsão da rugosidade da superfície em processo de usinagem por jato de água abrasivo. Em (34), Panda and Mahapatra aplicaram PCA para treinar NN e prever o desgaste da broca. Em (35) foi aplicado ANN para o desenvolvimento de um sistema de monitoramento, diagnóstico e prognóstico implementado em processos de usinagem industriais. Pontes et al. (36), apresentaram um estudo de NN com funções de base radial (RBF - *Radial Basis Function*) para a predição da rugosidade em processo de torneamento. Huang et al. (37) constatou que os sistemas tradicionais de detecção de falha de ferramenta deixam a desejar na habilidade de auto aprendizado, logo eles desenvolveram abordagem utilizando uma rede neural probabilística (PNN - *Probabilistic Neural Network*) para detecção da quebra da ferramenta em processos de fresagem. Os autores em (38) aplicaram floresta randômica para prever os perfis de microdureza e granularidade assim como o efeito dos parâmetro de corte na integridade da superfície. Em (39), um modelo para avaliação da saúde e previsão de vida de ferramentas de corte é proposto com base na redução de recursos não lineares e regressão por vetores de suporte (SVR - *Support Vector Regression*). Além disso, os autores em (40) propuseram um modelo baseado em ANN, com retropropagação de Levenberg-Marquardt, para otimizar a redução de energia de corte no processo de fresamento com quantidade mínima de lubrificação (MQL - *Minimum Quantity Lubrication*).

Em (41) foi conduzido um estudo comparativo utilizando algoritmos de máquinas de vetores de suporte (SVM - *Support Vector Machine*), ANN e floresta randômica focados na predição do desgaste de flanco em operações de fresagem monitorando forças de corte, vibrações e emissões acústicas. Também monitorando essas mesmas variáveis em (42) foi implementado PCA e ANN com o objetivo de monitorar as condições da ferramenta durante processo de torneamento à seco e também durante a perfuração de laminados plásticos reforçados com fibra de carbono (43). De forma similar, usando RBF PCA e GPR, autores em (44) propuseram um método para a previsão do desgaste da ferramenta. Em (8) foi empregado redes neurais convolucionais (CNN - *Convolutional Neural Network*) utilizando atributos baseados na transformada de wavelet extraídos de sinais de força e vibração, como um poderoso indicador de falha observando os sinais em tempo e frequência para operação de fresamento. Uma abordagem baseada em emissões acústicas foi proposta em (45) utilizando árvore de decisões e SVM para a classificação da condição da ferramenta

na usinagem de alta velocidade de liga de titânio. Chen et al. (46) aplicou redes de crenças profundas (DBN - *Deep Belief Network*) para prever o desgaste de flanco da ferramenta de corte. Autores em (47) propuseram um sistema de predição capaz de prever o desgaste e a quebra da ferramenta durante o processo de torneamento utilizando redes de aprendizado profundo. Em (48) foi desenvolvido um modelo oculto de markov (HMM - *Hidden Markov Model*) para estimação do desgaste da ferramenta e predição do tempo de vida útil restante da mesma em processos de micro-fresagem. Autores em (49) desenvolveram um modelo de diagnóstico de falhas utilizando redes de aprendizado profundo para máquinas rotativas. Liu et al. (7) propôs uma abordagem que reduz a complexidade do monitoramento em tempo real considerando a característica de repetição do processo de usinagem. Em (50) um modelo de monitoramento de desgaste de ferramenta multi-sensorial utilizando SVM foi aplicado para processos de fresagem de ligas de titânio capaz de reconhecer os estágios de desgaste da ferramenta. Autores em (51) introduziram uma abordagem para monitoramento da condição da ferramenta a partir de análises de vibração de processos de fresagem utilizando SVM. O método proposto em (52) emprega autoencoders para analisar os sinais de corrente das três fases do motor de giro do torno e monitorar o desgaste da ferramenta. Em (53) é proposta uma abordagem baseada em métodos aprendizado profundo utilizando redes de memória de longo e curto prazo (LSTM - *Long Short-Term Memory*) integrado com uma CNN residual para prever o desgaste de flanco baseado em dados históricos.

A literatura apresenta inúmeros modelos de aprendizado de máquina aplicado ao problema de usinagem. As técnicas de aprendizado de máquina permitem que intervenções sejam realizadas exclusivamente quando são observadas anomalias. A CBM baseado nestas técnicas minimiza o tempo improdutivo na manutenção, reduzindo o impacto da troca de ferramenta nos processos de usinagem. Apesar da crescente importância do aprendizado de máquina na indústria 4.0, no processo de usinagem, essas técnicas estão principalmente relacionadas a redes neurais empregadas em fresamento, EDM e furação, ou quando aplicadas à problemas de torneamento frequentemente englobam análises de vibração. Mesmo quando sendo observadas a corrente e tensão do motor do torno (54, 55, 56), as técnicas de aprendizado de máquina focadas em um pré-processamento por meio de extração e seleção de atributos classificação de ferramentas de corte de torno têm um potencial inexplorado.

## 1.2 OBJETIVOS

O presente trabalho tem como objetivo o desenvolvimento de um protótipo de baixo custo, com o intuito de ser acessível e viável em comparação com sistemas de aquisição de dados disponíveis no mercado, para aquisição de dados em tempo real. Também como objetivo deste trabalho temos um modelo capaz de identificar padrões para executar a

classificação da condição de operação de ferramentas de corte de um motor de torno em três classes. Com essa finalidade propõe uma caracterização das séries temporais da corrente de alimentação das três fases do motor de giro de um torno de forma comparativa com uma simplificação matemática do processo. Este trabalho também propõe uma extensão do método TSFRESH e do teste de KS para um cenário multiclasse, aplicado à um problema real de engenharia mecânica para detecção de falhas de ferramentas de corte de torno e classificação da ferramenta em relação ao estágio de sua vida. O ciclo de vida da ferramenta neste trabalho foi dividido entre condição adequada de operação, condição intermediária e condição inadequada de operação.

### 1.3 CONTRIBUIÇÕES

Podemos elencar como principais contribuições desse trabalho:

- O desenvolvimento de um protótipo de baixo custo para aquisição e armazenamento de dados de corrente e tensão das três fases do motor do torno com uma interface intuitiva para o operador do torno permitindo que ele obtenha informações importantes sobre o desempenho da ferramenta de corte, identifique potenciais problemas e realize a manutenção preventiva do equipamento. Facilitando a utilização pelo operador, que não precisa ter conhecimentos avançados em eletrônica ou programação para operá-lo.
- A caracterização de séries temporais da corrente de alimentação das três fases do motor de giro de um torno, obtidas através de sucessivos ensaios de usinagem que compreendem o ciclo completo de vida de uma ferramenta de corte feita de forma comparativa com uma simplificação matemática do processo.
- A proposta de um método baseado em testes de hipóteses escalonáveis para um cenário multiclasse. Esse método torna possível prever o desgaste da ferramenta em um estágio intermediário pré-falha, prevenindo então operações com a ferramenta em condições inadequadas de funcionamento.
- A apresentação e avaliação de duas diferentes soluções para aplicar a seleção de atributos multiclasse em uma base de dados adquirida através de operações reais de usinagem utilizando um protótipo de aquisição de dados de baixo custo desenvolvido no Laboratório de Automação Industrial e Inteligência Computacional (LAIIC) da Universidade Federal de Juiz de Fora (UFJF).
- A proposta de uma abordagem autônoma para classificar ferramentas de corte em um cenário multiclasse (condição adequada, intermediária e inadequada) aumentando a confiabilidade do processo de usinagem.

## 1.4 ORGANIZAÇÃO DO TRABALHO

A presente dissertação foi organizada da seguinte forma:

- O Capítulo 2 aborda a formulação do problema, apresentando uma fundamentação teórica sobre o desgaste de flanco de uma ferramenta de corte de torno.
- O Capítulo 3 descreve o protótipo de aquisição de dados de baixo custo desenvolvido durante a execução do trabalho e também mostra as ferramentas para a análise do processo estocástico adquirido a fim de validar o protótipo de aquisição de dados. Este capítulo ainda descreve o modelo de classificação de ferramenta de corte de torno em um cenário multiclasse.
- O Capítulo 4 apresenta a base de dados e a forma como foi coletada. Discute uma análise comparativa entre a base de dados e as realizações simuladas do processo estocástico que representa o motor de giro do torno. E também neste capítulo será apresentado os resultados do modelo de classificação multiclasse.
- O Capítulo 5, por fim, descreve as conclusões, observações finais do trabalho e a apresentação de trabalhos futuros.

## 1.5 PUBLICAÇÕES

Esta dissertação foi fundamentada pelos artigos publicados nos seguintes periódicos/eventos:

- CBA 2022 (57)

Thiago Estercei Fernandes, **Matheus Augusto Malta Ferreira**, Guilherme Pires Carneiro de Miranda, Marcos Victor Gomes Ribeiro da Silva, Eduardo Pestana de Aguiar, *Multivariate Time Series and Machine Learning Techniques for the multi-class Classification of Lathe's Cutting Tools Wear Condition* - XXIV Congresso Brasileiro de Autimática - 2022.

- SBrT 2022 (58)

**Matheus Augusto Malta Ferreira**, Thiago Estercei Fernandes, Guilherme Pires Carneiro de Miranda, Marcos Victor Gomes Ribeiro da Silva, Eduardo Pestana de Aguiar, *Análise de Relevância de Atributos para Classificação de Falhas de Ferramentas de Corte Utilizando TSFRESH* - XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - 2022 - DOI: <http://dx.doi.org/10.14209/sbrt.2022.1570823732>.

- JCAE 2022 (59)

Thiago Estercei Fernandes, **Matheus Augusto Malta Ferreira**, Guilherme Pires Carneiro de Miranda, Alexandre Freire Dutra, Matheus Pereira Antunes, Marcos Victor Gomes Ribeiro da Silva, Eduardo Pestana de Aguiar, *Classification of Lathe's Cutting Tool Wear Based on an Autonomous Machine Learning Model* - Journal of Control, Automation and Electrical Systems, 33, 167-182 - 2022 - DOI: <https://doi.org/10.1007/s40313-021-00819-5>.

- CBA 2020 (60)

Thiago Estercei Fernandes, Guilherme Pires Carneiro de Miranda, Alexandre Freire Dutra, **Matheus Augusto Malta Ferreira**, Matheus Pereira Antunes, Marcos Victor Gomes Ribeiro da Silva, Eduardo Pestana de Aguiar, *An Autonomous Model to Classify Lathe's Cutting Tools Based on TSFRESH, Self-Organised Direction Aware Data Partitioning Algorithm and Machine Learning Techniques* - XXIII Congresso Brasileiro de Automática - 2020 - DOI: <https://doi.org/10.48011/asba.v2i1.1092>.

*Trabalho premiado no evento como menção honrosa na categoria artigos de graduação.*

## 2 FORMULAÇÃO DO PROBLEMA

As variáveis que compõem as series temporais utilizadas neste trabalho foram definidas com o objetivo de monitorar e diagnosticar o desgaste nas ferramentas de corte. O crescimento da potência consumida pelo torno pode ser explicada pelo fato da evolução do desgaste de flanco na ferramenta causar um aumento na área de contato entre a ferramenta e a peça. Conseqüentemente, existe um aumento no atrito e nas forças de usinagem, o que resulta no aumento do consumo de potência. Logo tensão e corrente elétrica do motor do torno foram definidas como as variáveis a serem observadas, já que a potência de corte tem recebido grande atenção na literatura. A análise dessas grandezas são justificadas devido ao fato de que o torno necessita de mais energia quando está operando com uma ferramenta ruim do que estaria consumindo caso estivesse funcionando com uma ferramenta boa (61). Entretanto, trabalhos anteriores (59, 58) contemplam uma detalhada análise dos sensores e dos atributos exibindo que a corrente das três fases do motor do torno são relevantes para a classificação da ferramenta. Dessa forma, no presente trabalho será avaliada somente a corrente das três fases do motor de giro do torno.

O desgaste de flanco ocorre quando uma parte da ferramenta sofre erosão devido ao contato com o material que está sendo usinado. A evolução do desgaste de flanco em uma ferramenta de corte utilizada nos experimentos pode ser observado na Figura 1.

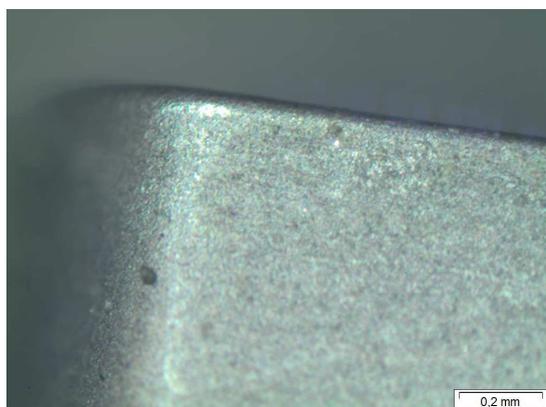
Além disso, este trabalho aplica análises estatísticas observando a distribuição e a variância nos atributos extraídos conjunto de dados, como PCA e TSFRESH em busca de selecionar atributos pertinentes para a classificação e assim reduzir a complexidade computacional do modelo apresentado. Na literatura, a força de corte é considerada essencialmente uma função da velocidade de corte, do avanço e da profundidade do corte, conseqüentemente o desgaste da ferramenta depende dos mesmos parâmetros (62).

Devido ao inversor de frequências do motor do torno que faz um controle da velocidade do motor com ajuste automático das variações de carga e rede. Este controle conta com algoritmos inseridos no software de controle que irão alterar a relação entre tensão e frequência para ajustar o torque. Desta forma, a frequência de disparo do inversor se altera pela carga, portanto ao usinar uma peça, quanto menor o diâmetro desta, a frequência de disparo aumenta para manter o torque. Logo, as componentes de frequência relacionadas com disparo do inversor podem ser prejudiciais ao modelo por potencializarem a separação de dados de mesmo estado de desgaste, porém com diâmetros diferentes. Assim, não somente o consumo de potência é alterado com o desgaste da ferramenta, mas também os padrões das séries temporais (58).

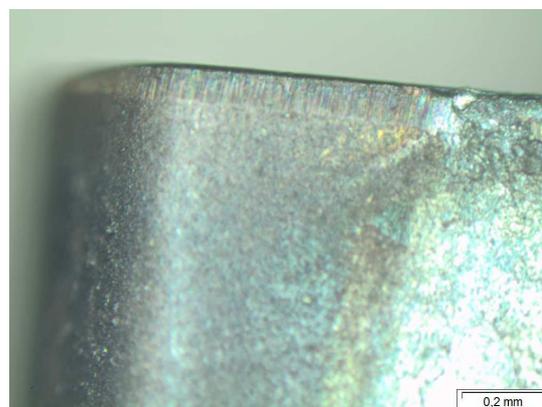
As séries temporais utilizadas neste trabalho são coletas de tensão e corrente das três fases do motor de giro do torno. As séries temporais foram registradas a partir de operações em um sistema real de usinagem presente no Serviço Nacional de Aprendizagem Industrial

Figura 1 - Evolução do Desgaste de Flanco na Ferramenta

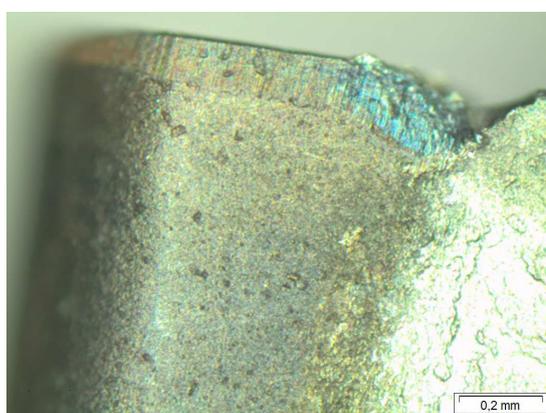
(a) Condição Adequada



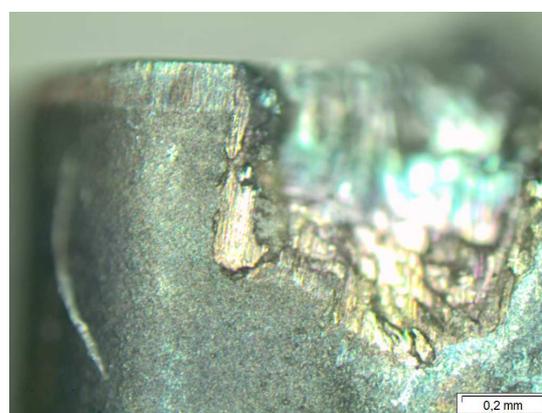
(b) Condição Adequada



(c) Condição Intermediária



(d) Condição Inadequada



Fonte: Elaborada pelo autor (2022).

(SENAI) em colaboração com o Laboratório de Automação Industrial e Inteligência Computacional (LAIIC). O procedimento utilizado neste trabalho é regulamentado pela ISO 3685/1993. Consiste em executar sucessivos passes de usinagens com a ferramenta e examinar em intervalos regulares a sua condição de desgaste. Este processo é repetido até que o desgaste da ferramenta atinja um limite pré-estabelecido. Considerando as diretrizes técnicas da ISO 3685/1993, o limite adotado foi o comprimento máximo do desgaste de flanco de  $0,6\text{mm}$ . Assim, o desgaste de flanco superior ao limite estabelecido foi considerado uma condição inadequada. Além disso, as condições de usinagem foram: profundidade de corte de  $0,5\text{mm}$ , velocidade de corte de  $120\text{m}/\text{min}$  e avanço de  $0,156\text{ mm}/\text{rot}$ .

O processo de usinagem foi executado em um Centro de Torneamento Romi GL280M 2014 com CNC da FANUC que pode ser visto na Figura 2. Esta máquina foi equipada com um conjunto de pastilhas intercambiáveis TNUX 160-404 R LT 1000. Entretanto, trabalhos anteriores foram executados em um torno manual universal Timemaster Tb 350 (60, 59) a fim de validar o modelo em diferentes cenários.

As séries temporais foram adquiridas durante os experimentos utilizando um sistema

de aquisição de dados desenvolvido no Laboratório de Automação Industrial e Inteligência Computacional (LAIIC).

Figura 2 - Centro de Torneamento Romi GL280M 2014 com CNC da FANUC.



Fonte: Catálogo Linha ROMI GL - Industrias Romi S.A. (2012).

### 3 SISTEMA DE AQUISIÇÃO E CLASSIFICAÇÃO MULTICLASSE DE SÉRIES TEMPORAIS MULTIVARIADAS

Neste capítulo será apresentado o protótipo de aquisição de dados desenvolvido para a execução deste trabalho, as ferramentas estatísticas de caracterização de um processo estocástico que serão utilizadas para a validação das aquisições e o modelo de classificação multiclasse de séries temporais multivariadas.

#### 3.1 SISTEMA DE AQUISIÇÃO DE DADOS

O sistema de aquisição de dados desenvolvido no LAIIC (Laboratório de Automação Industrial e Inteligência Computacional) é composto por um módulo eletrônico que tem a função de adquirir, processar e armazenar os dados provenientes dos sensores utilizados no experimento. O sistema é capaz de converter os sinais analógicos capturados pelos sensores em sinais digitais, garantindo a qualidade e a precisão dos dados coletados.

O armazenamento dos dados coletados é realizado em um cartão SD, que é facilmente removível e pode ser transferido para outros dispositivos para análise posterior. Isso permite a geração de relatórios, análise estatística e outras atividades que ajudam na avaliação do desempenho dos processos industriais.

O sistema de aquisição de dados desenvolvido permite a coleta de dados de forma precisa e eficiente, auxiliando na tomada de decisões e na melhoria dos processos produtivos.

Foram utilizados três sensores de corrente SCT-013 e três sensores de tensão ZMPT101B-250V, conectados às três fases do motor de giro do torno para realizar a aquisição dos dados de corrente e tensão. Os sensores de corrente foram escolhidos por serem não invasivos e capazes de operar com sinais de até  $\pm 100A$ , enquanto que os sensores de tensão foram selecionados por possuírem uma faixa de operação de  $\pm 250V$ .

Os sensores foram projetados para aquisitar os sinais analógicos e converterem-nos em sinais digitais, com uma saída entre 0 e 5V, o que permite a interface com outros dispositivos eletrônicos de maneira fácil e eficiente.

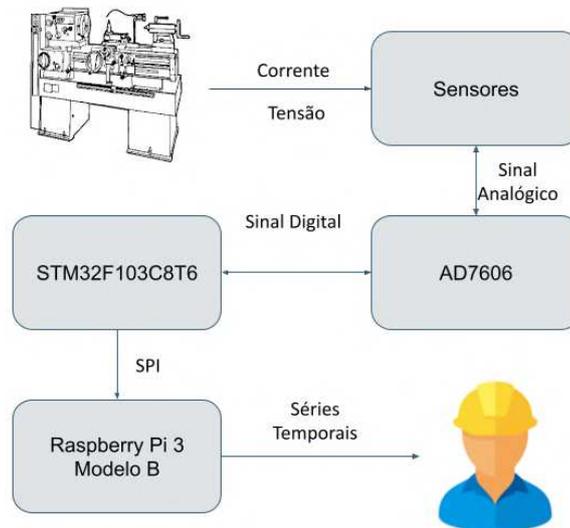
Para garantir a acurácia necessária nas medidas realizadas pelo módulo de aquisição de dados, foi necessário utilizar um conversor analógico/digital (ADC) de alta precisão. Nesse sentido, optou-se pelo uso do AD7606, um ADC de 16 bits da Analog Devices.

O AD7606 foi selecionado por sua alta resolução e taxa de amostragem, o que permite a captura de sinais de alta frequência com grande precisão. Além disso, o dispositivo possui um conjunto de recursos avançados de filtragem, permitindo a remoção de ruídos e interferências indesejadas presentes nos sinais adquiridos.

Após a conversão dos sinais analógicos para digitais, os dados são enviados para um microcontrolador STM32F407ZGT6, responsável pelo processamento e armazenamento

dos dados obtidos. A Figura 3 apresenta o fluxo do sistema de aquisição de dados utilizado, demonstrando a interação dos diversos componentes e a sequência de operações realizadas pelo sistema.

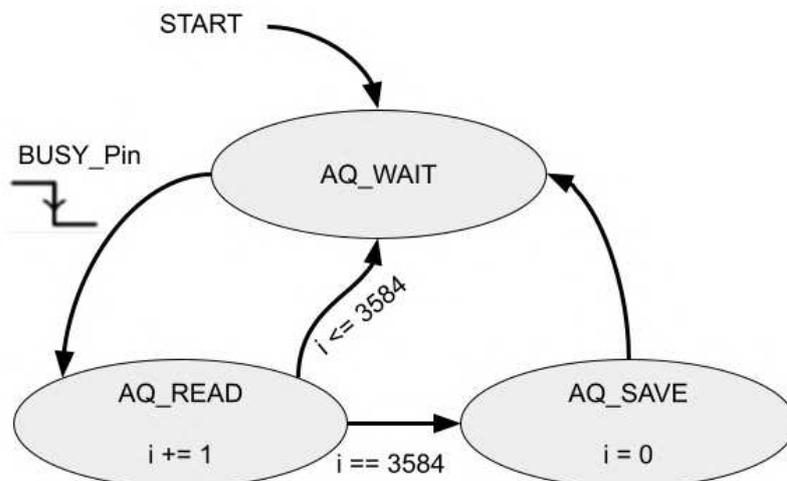
Figura 3 - Fluxo de Aquisição do Protótipo.



Fonte: Elaborada pelo autor (2022).

O STM32F407ZGT6 é baseado no processador de alta performance Arm Cortex-M4 32-bit RISC core e opera numa frequência de até 168 MHz, com uma capacidade de 1 MB de memória Flash e 192 Kb SRAM. Na Figura 4 uma máquina de estados finita (FSM - *Finite States Machine*) explica o algoritmo presente no STM32F407ZGT6.

Figura 4 - Diagrama do Algoritmo do STM32F407ZGT6.



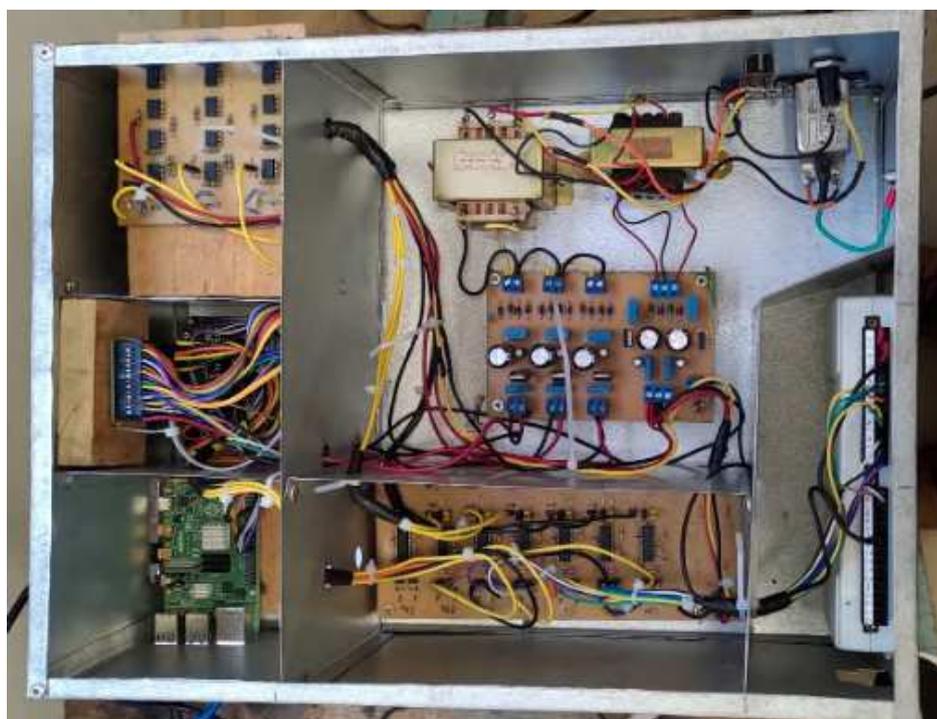
Fonte: Elaborada pelo autor (2022).

Os estados da FSM podem ser descritos como:

- **AQ\_WAIT**: Espera pela borda de descida do pino *BUSY\_Pin*, fim da conversão analógico digital do AD7606;
- **AQ\_READ**: Lê os sinais e armazena na memória uma amostra de cada canal do AD7606. Incrementa *i*;
- **AQ\_SAVE**: Quando  $i == 3584$  (tamanho de uma realização) salva a realização no cartão SD e reinicia o valor de *i*.

O sistema de aquisição de dados desenvolvido neste trabalho pode ser visto na Figura 5.

Figura 5 - Sistema de Aquisição de Dados.



Fonte: Elaborada pelo autor (2022).

### 3.2 CARACTERIZAÇÃO DO PROCESSO ESTOCÁSTICO

Um processo estocástico pode ser definido como uma sequência de variáveis aleatórias indexadas ao tempo definida sobre um espaço de probabilidades. Suponha que para um dado valor de  $t$ ,  $X_t$  se origine de um experimento que pode ser repetido em condições idênticas. Então a cada repetição  $x_t$  obtém-se um registro de valores de  $X_t$  no tempo que é uma realização de um processo estocástico. Sendo assim, uma série temporal, que

é um conjunto de observações de uma determinada variável  $X$  geradas sequencialmente no tempo, também pode ser definida como sendo uma parte da trajetória, ou de uma realização parcial, uma amostra finita, de um processo estocástico.

Para validar as leituras do protótipo de aquisição de dados, serão geradas séries temporais simuladas referentes ao motor de giro do torno, que serão comparadas com as séries temporais medidas pelo protótipo. Essa abordagem permite avaliar a qualidade das leituras obtidas pelo protótipo de forma objetiva e quantitativa, por meio da análise comparativa dos processos estocásticos subjacentes às séries temporais.

Essa caracterização dos processos estocásticos pode fornecer informações valiosas sobre o comportamento do motor de giro do torno, tais como a identificação de padrões de variação ao longo do tempo, a detecção de anomalias e a previsão de falhas. Além disso, a abordagem adotada pode ser aplicada a outros sistemas mecânicos, elétricos ou eletrônicos, contribuindo para o desenvolvimento de técnicas de monitoramento e diagnóstico de falhas em tempo real.

### 3.2.1 Ferramentas de Caracterização

Os processos estocásticos podem ser classificados em estacionários e não estacionários, sendo os primeiros caracterizados por uma média e variância constantes no tempo e por uma função de autocorrelação que depende somente do atraso entre as amostras. Dentre os processos estocásticos estacionários, os processos de segunda ordem têm sido amplamente utilizados na modelagem de séries temporais em diversos campos de aplicação. Nesse tipo de processo, a média e a variância do processo são constantes no tempo e a função de autocorrelação é apenas função do atraso entre as amostras. Nesse contexto, a caracterização dos processos estocásticos relacionados às leituras das séries temporais obtidas pelo protótipo de aquisição de dados pode fornecer informações valiosas sobre a dinâmica do sistema em questão e permitir a validação das leituras obtidas.

#### 3.2.1.1 Média

A média ou valor esperado de uma variável aleatória  $X(t)$  é definida como o valor médio de todas as suas possíveis realizações em um instante  $t$ . É expressa pela seguinte equação:

$$\mu_X(t) = E[X_t] = \int_{-\infty}^{\infty} x f_X(x; t) dx, \quad (3.1)$$

em que  $f_X(x; t)$  é a função densidade de probabilidade (PDF - *Probability Density Function*) da variável aleatória  $X(t)$ .

Se  $X(t)$  for pelo menos estacionário de 1<sup>a</sup> ordem,  $f_{X(t)}(x) = f_X(x)$  e  $\mu_X(t) = \mu_X = cte.$  para todo  $t$ .

Para fins práticos, a média é estimada a partir de um conjunto de  $N$  realizações  $X_k[n]$  do processo  $X$  em um dado instante  $n$ , dada pela seguinte equação:

$$\mu_X[n] = \frac{1}{N} \sum_{k=1}^N X_k[n], \quad (3.2)$$

em que  $n$  é o instante de tempo considerado.

### 3.2.1.2 Autocorrelação

A autocorrelação é uma medida estatística importante para análise de processos estocásticos e é definida como o valor esperado do produto das variáveis aleatórias do processo em dois instantes diferentes. Para um processo estocástico  $X(t)$ , a autocorrelação  $R_{XX}(t_1, t_2)$  pode ser dada pela seguinte equação:

$$R_{XX}(t_1, t_2) = E[X_{t_1}X_{t_2}] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1x_2f(x_1, x_2; t_1, t_2)dx_1dx_2, \quad (3.3)$$

em que  $f(x_1, x_2; t_1, t_2)$  é a função densidade de probabilidade (PDF - *Probability Density Function*) conjunta de  $X(t_1)$  e  $X(t_2)$ .

Para um processo estacionário de 2ª ordem, a função de autocorrelação depende apenas da diferença entre os instantes  $t_1$  e  $t_2$ , ou seja, é uma função somente do atraso  $\tau = t_2 - t_1$ . Dessa forma, pode-se escrever:

$$R_{XX}(\tau) = E[X_tX_{t+\tau}] \quad (3.4)$$

A função de autocorrelação é uma medida útil para caracterizar a correlação entre as amostras do processo estocástico em diferentes instantes. Para fins práticos, a função de autocorrelação pode ser estimada a partir das realizações do processo por meio da equação:

$$\hat{R}_{XX}[k] = \frac{1}{N} \sum_{n=0}^{N-k} x[n]x^{(k)}[n-k], \quad (3.5)$$

em que  $x^{(k)}[n]$  representa  $x[n]$  com um deslocamento circular positivo de tamanho  $k$  e  $x$  é uma realização do processo. A estimativa  $\hat{R}_{XX}[k]$  é uma aproximação da função de autocorrelação verdadeira  $R_{XX}[k]$ , sendo a média de várias estimativas uma forma de reduzir o erro de estimativa.

### 3.2.1.3 Densidade Espectral de Potência

Seja  $x[n]$  um processo de tempo discreto com função de autocorrelação  $R_{XX}(\tau)$ . A densidade espectral de potência de tempo discreto desse processo é definida como:

$$S_{XX}(\omega) = \sum_{k=-\infty}^{\infty} R_{XX}(k)e^{-j\omega kT} \quad (3.6)$$

A estimação da densidade espectral de potência pode ser feita aplicando a Transformada Rápida de Fourier (FFT - *Fast Fourier Transform*) na função de autocorrelação estimada, resultando na equação abaixo.

$$\hat{S}_{XX}(\omega) = fft(\hat{R}_{XX}[k]) \quad (3.7)$$

### 3.2.2 Caracterizações

Um processo estocástico pode ser caracterizado tanto pela sua estacionariedade quanto pela sua ergodicidade.

#### 3.2.2.1 Estacionariedade

Se  $X(t)$  é tal que  $\mu_{x(t)}$  é constante e  $R_{XX}(t, t + \tau)$  depende apenas de  $\tau$ , o processo é dito estacionário em sentido amplo (WSS - *Wide-Sense Stationary*).

#### 3.2.2.2 Ergodicidade

Um processo estocástico estacionário é ergódico se todas as suas estatísticas podem ser determinadas a partir de uma função amostra qualquer  $X(t)$  representante de uma possível realização do processo, ou seja, através de suas médias temporais.

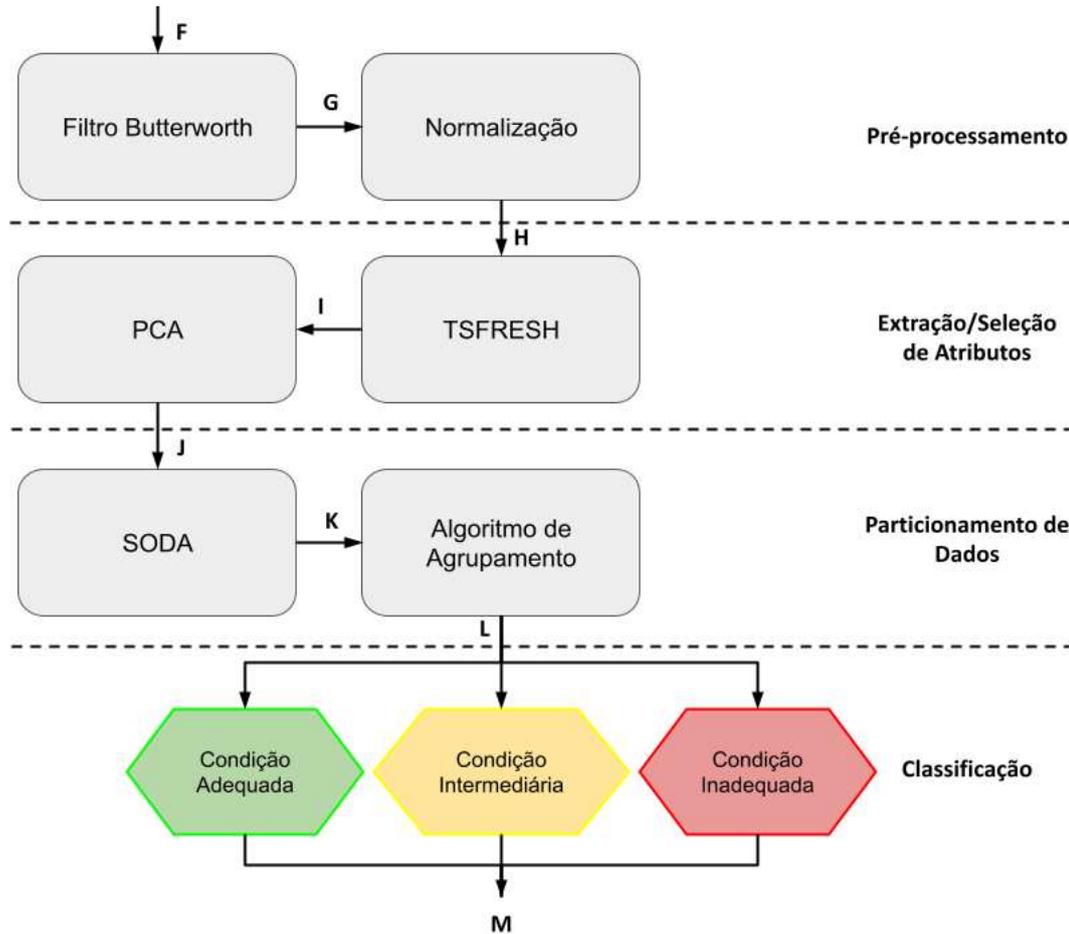
## 3.3 MODELO DE CLASSIFICAÇÃO MULTICLASSE DE SÉRIES TEMPORAIS MULTIVARIADAS

A estrutura do modelo é apresentada na Figura 6. A base de dados utilizada nesse trabalho consiste em 785 series temporais aquisitadas com o protótipo descrito na Seção 3.1. Cada série temporal consiste em 3584 medidas de tensão e corrente elétrica de cada fase do motor do torno. Portanto, a matriz  $\mathbf{F}$  consiste nos dados aquisitados que é apresentada a um estágio de pré-processamento, que se inicia com a filtragem e normalização da matriz, resultando na matriz  $\mathbf{H}$ .

Após o estágio de pré-processamento, a matriz  $\mathbf{H}$  é apresentada ao algoritmo TSFRESH, que é responsável por extrair 77 atributos diferentes de cada variável da série temporal, assim como selecionar, através de teste de hipóteses, qual desses atributos é relevante para caracterizar a ocorrência de falhas. A saída do TSFRESH consiste em uma matriz  $\mathbf{I}$ .

Com a intenção de reduzir a dimensionalidade da matriz  $\mathbf{I}$ , foi aplicado o PCA. A saída do PCA, representada por  $\mathbf{J}$ , consiste na projeção dos dados da matriz  $\mathbf{I}$  em um novo sistema de coordenadas, formado por eixos chamados de Componentes Principais (PC's - *Principal Components*), o número de componentes principais utilizadas no decorrer do processo é fixo e previamente definido a fim de manter uma representatividade satisfatória

Figura 6 - Modelo Proposto



Fonte: Elaborada pelo autor (2022).

na redução da dimensionalidade. Note que após essa projeção, os dados na matriz **J** não podem ser diretamente relacionados à um sensor específico ou a um atributo específico extraído pelo TSFRESH, já que as PC's são calculadas pela variação dos dados, envolvendo todas as dimensões da matriz **I**.

Com o objetivo de agrupar os dados da matriz **J** em nuvens de dados, o módulo de particionamento dos dados se inicia apresentando a matriz **J** ao algoritmo SODA. As nuvens de dados são formadas calculando métricas de distância e dissimilaridade entre os eventos. Consequentemente, a saída do SODA, representada por **K**, consiste nos mesmos dados presentes na matriz **J**, mas com rótulos descrevendo a qual nuvem de dados o evento pertence.

Em seguida, o módulo de particionamento de dados é concluído pelo algoritmo de agrupamento, que une as nuvens de dados em três grupos: ferramenta em condição adequada, ferramenta em condição intermediária e ferramenta em condição inadequada. Como o SODA é um algoritmo auto-organizável, a sua saída pode consistir em um número de classes maior do que o necessário para resolver o problema. Assim as nuvens de

dados devem ser agrupadas de forma que na saída existam três grupos de classificação da ferramenta, sendo estes, ferramenta adequada, ferramenta intermediária e ferramenta inadequada. Logo, a saída do algoritmo de agrupamento, representada por  $\mathbf{L}$ , é muito similar a matriz  $\mathbf{K}$ , nesta etapa cada evento recebe um novo rótulo, designado por este algoritmo.

Finalmente, os dados são apresentados ao módulo de classificação, a matriz  $\mathbf{K}$  é usada para treinar diferentes classificadores com a tarefa de classificar condição da ferramenta de corte.

### 3.3.1 Filtragem

A primeira etapa do modelo compreende a filtragem das séries temporais. Será aplicado um filtro Butterworth passa baixa de segunda ordem e frequência de corte de 200 Hz para manter a frequência da rede e eliminar as componentes de alta frequência do sinal (58). A equação de um filtro de Butterworth passa baixa pode ser dada da seguinte maneira:

$$G(s) = \frac{A}{s^2 + 2\xi\omega_n s + \omega_n^2}, \quad (3.8)$$

em que  $A$  é o ganho do filtro,  $\xi$  o amortecimento do sistema e  $\omega_n$  a frequência de corte em  $rad/s$ .

As vantagens de se usar um filtro Butterworth de segunda ordem é a sua semelhança com um filtro ideal devido à elevada queda de 40 dB/década na banda de corte, o ganho constante na banda de passagem e a possibilidade de implementar o filtro a nível de hardware com o uso de resistores, capacitores e amplificador operacional.

### 3.3.2 Normalização

Seja  $\mathbf{G}$  um conjunto de séries temporais, em que  $\mathbf{G} = \mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_j$  com  $j = 785$ , em que  $\mathbf{t}_k$  representa a  $k$ -ésima série temporal dos valores de tensão e corrente de  $\mathbf{T}_k$  normalizados. A normalização aplicada segue a equação 3.9.

$$\mathbf{t}_k(i, j) = \frac{\mathbf{T}_k(i, j) - \mu_i}{\sigma_i}, \quad (3.9)$$

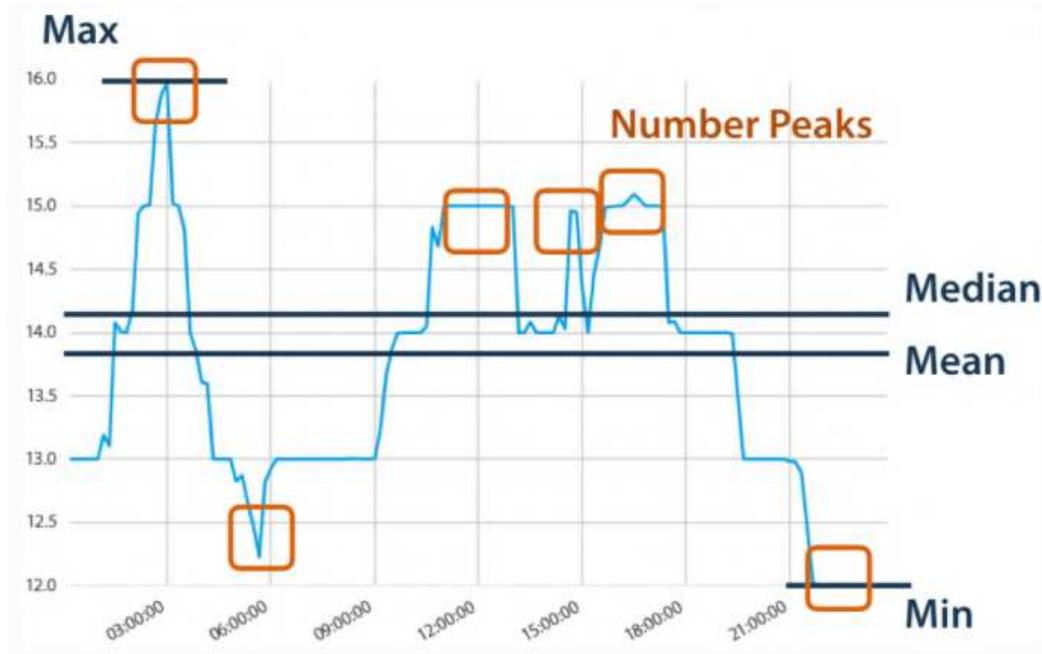
em que  $\mathbf{t}_k(i, j)$  é o valor normalizado da  $i$ -ésima variável na  $j$ -ésima medição,  $\mu_i$  é a média da série temporal e  $\sigma_i$  é o desvio padrão da variável correspondente. Note que cada variável das séries temporais é normalizada independentemente.

### 3.3.3 Extração de Atributos Baseada em Testes de Hipóteses Escalonáveis (TSFRESH)

A extração de atributos é feita utilizando o algoritmo TSFRESH, uma biblioteca do Python, que consiste na extração de 77 atributos para cada série temporal, a lista

completa de atributos extraídos pode ser vista em: [https://tsfresh.readthedocs.io/en/latest/text/list\\_of\\_features.html](https://tsfresh.readthedocs.io/en/latest/text/list_of_features.html). Um exemplo de atributos extraídos das series temporais pode ser visto na Figura 7.

Figura 7 - Exemplos de Atributos Extraídos pelo TSFRESH.



Fonte: Documentação do TSFRESH (63) (2022).

Considerando  $X$  um atributo calculado para uma das variáveis, com  $\mathbf{t}_k$ , a  $k$ -ésima série temporal de  $\mathbf{H}$ , a relevância de  $X$  para a classificação  $Y$  é calculada a partir de sua função de distribuição acumulada (13, 64), expressa como  $f_{X|Y=y_1}$  e  $f_{X|Y=y_2}$ , em que  $y_1$  e  $y_2$  são o conjunto de valores para um atributo  $X$  calculado para as séries temporais de condições de operação diferentes das ferramentas. Assim, o atributo  $X$  é relevante para estimar  $Y$  se, e somente se:

$$\exists y_1, y_2 \text{ para } f_Y(y_1), f_Y(y_2) > 0 : f_{X|Y=y_1} \neq f_{X|Y=y_2} \quad (3.10)$$

A equação 3.10 também corresponde à  $X$  e  $Y$  serem estatisticamente dependentes. O atributo  $X$  é irrelevante quando:

$$\exists y_1, y_2 \text{ with } f_Y(y_1), f_Y(y_2) > 0 : f_{X|Y=y_1} = f_{X|Y=y_2}, \quad (3.11)$$

o que também implica que  $X$  e  $Y$  são estatisticamente independentes.

A relevância também pode ser investigada através de testes de hipóteses (65). O teste de hipóteses é independentemente aplicado ao atributo extraído  $X_i$ , em ordem de investigar as seguintes hipóteses:

$$\begin{aligned} H_0^i &= \{X_i \text{ não é relevante para } Y\}, \quad i = 1, 2, \dots, n; \\ H_1^i &= \{X_i \text{ é relevante para } Y\}, \quad i = 1, 2, \dots, n; \end{aligned} \quad (3.12)$$

em que  $n$  é o número de atributos extraídos e  $H_0^i$  e  $H_1^i$  são, respectivamente, a hipótese nula e a alternativa relacionada ao  $i$  –ésima atributo extraído o resultado de cada teste é chamado de  $p$ -valor e corresponde à probabilidade de se obter uma estatística de teste igual ou mais extrema que aquela observada em uma amostra, baseada em hipótese nula.

O teste aplicado neste trabalho é o Teste de Kolmogorov-Smirnov (KS) (14), considerando as seguintes hipóteses:

$$\begin{aligned} H_0^i &= \left\{ f_{X_i|Y=y_1} = f_{X_i|Y=y_2} \right\}, \\ H_1^i &= \left\{ f_{X_i|Y=y_1} \neq f_{X_i|Y=y_2} \right\}, \end{aligned} \quad (3.13)$$

em que  $f_{X_i|Y=y_1}$  é a CDF obtida pela integral da PDF de cada atributo  $X_i$  considerando os ensaios da ferramenta em condição adequada  $f_{X_i|Y=y_2}$  é a CDF do atributo  $X_i$  considerando condição inadequada.

O teste de KS considera a diferença máxima entre as CDF's obtidas pelos atributos como pode ser visto na Equação 3.14.

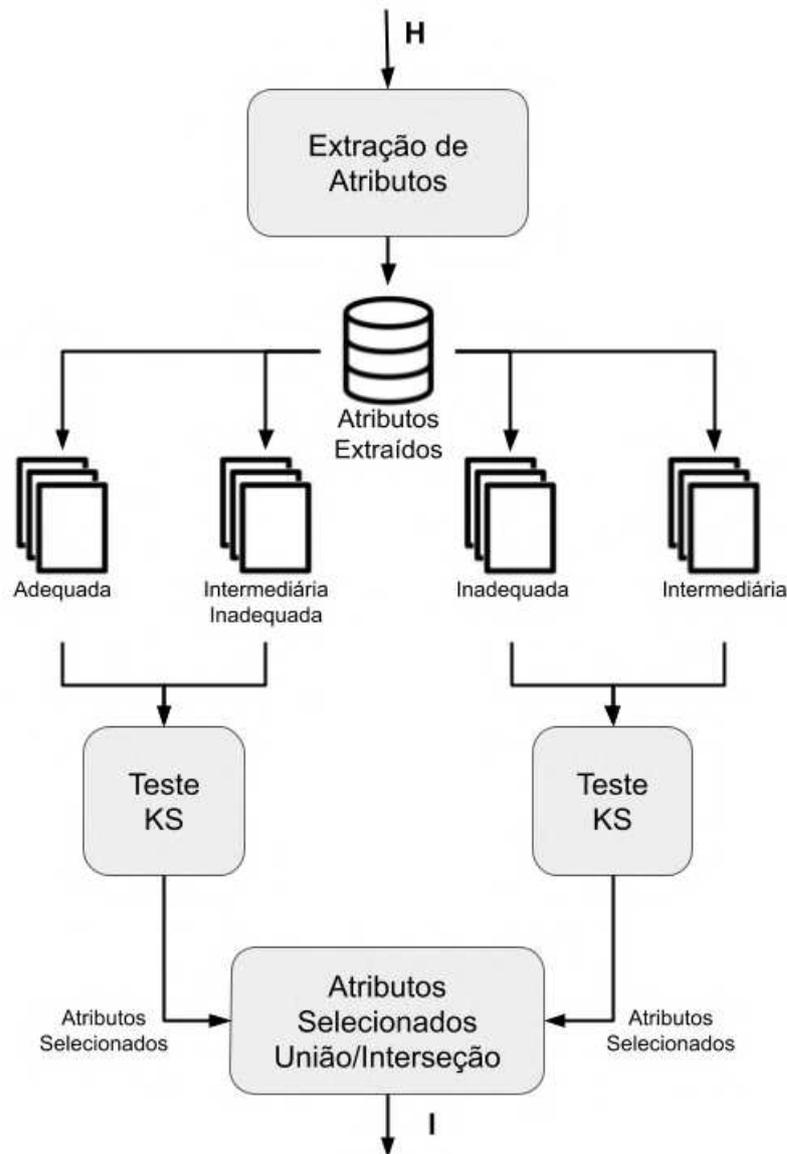
$$D = \sup |f_{X_i|Y=y_1} - f_{X_i|Y=y_2}| \quad (3.14)$$

É válido mencionar que o teste KS identifica os atributos que podem diferenciar duas classes. Entretanto, este trabalho lida com um problema multiclasse. Com o objetivo de obter os atributos que são capazes de distinguir entre todas as classes desejadas, a estratégia apresentada na Figura 8 foi aplicada.

Primeiramente o conjunto de dados é submetido à extração de atributos executada pelo TSFRESH. Os atributos extraídos são separados levando em consideração a sua classificação com o objetivo de executar o teste de KS duas vezes. Em uma das execuções do teste, busca-se selecionar os atributos capazes de distinguir uma ferramenta em condição adequada para as ferramentas de condição intermediária e inadequada. Paralelamente, o teste de KS é aplicado para selecionar os atributos capazes de distinguir uma ferramenta em condição intermediária para as ferramentas em condição inadequada.

Ao fim de ambas as execuções do teste de hipóteses são obtidas duas listas de atributos selecionados o algoritmo proposto seleciona tanto a união quanto a intersecção entre as duas listas de atributos resultantes por ambos os testes de hipóteses. A saída do TSFRESH consiste na matriz **I**. A comparação entre os uso da intersecção ou união será apresentada no Capítulo 4.

Figura 8 - Descrição Detalhada do TSFRESH Multiclasse.



Fonte: Elaborada Pelo Autor (2022).

### 3.3.4 Análise de Componentes Principais (PCA)

O PCA é um método utilizado para reduzir a dimensionalidade do problema em componentes não correlacionadas que são combinações lineares das variáveis originais. Esse novo sistema de coordenadas constitui-se numa base ortonormal na qual todas as dimensões, chamadas de Componentes Principais (PC), são linearmente decorrelacionada das outras dimensões.

Dado um conjunto de atributos  $\mathbf{X} = X_1, X_2, \dots, X_n$ , em que  $n$  é o número de atributos selecionados pelo TSFRESH, é possível trabalhar com um conjunto menor de variáveis dentro de  $\mathbf{X}$ , em que suas combinações lineares  $\alpha_k \mathbf{X}$  preservam a maior parte da informação disponível com uma variação máxima. Essa variável é chamada de componente

principal e a primeira componente principal é  $z_1$ , que é composta pela maior variação dos dados.

As outras componentes são calculadas analogamente e a  $l$  –ésima componente principal não deve ser correlacionada com as componentes anteriores(15):

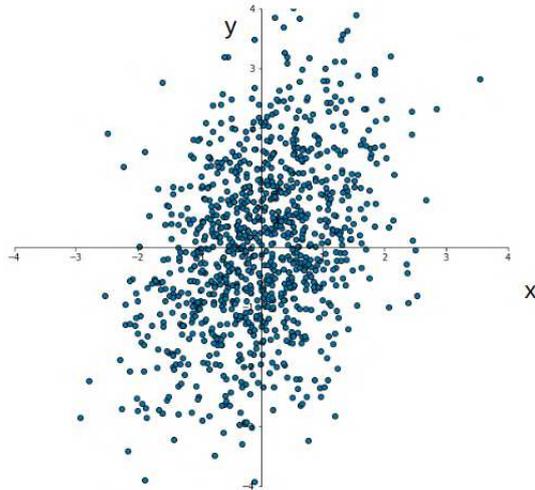
$$z_l = \alpha_{l1}x_1 + \alpha_{l2}x_2 + \dots + \alpha_{ln}x_n = \sum_{k=1}^n \alpha_{lk}x_k \quad (3.15)$$

Em sequência, as componentes calculadas são utilizadas para projetar os dados da matriz  $\mathbf{I}$  em um novo sistema de coordenadas com  $l$  dimensões. Este processo resulta na matriz  $\mathbf{J}_{j \times l}$  em que  $l$  é o número de componentes principais e  $j$  é o número de séries temporais processadas.

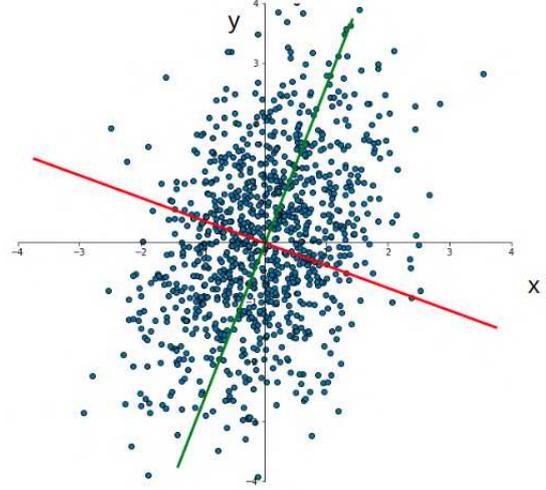
Um exemplo ilustrativo do funcionamento do PCA pode ser visto na Figura 9. A maior vantagem do PCA é a sua capacidade de transpor o conjunto de dados original em um novo sistema ortogonal e não correlacionado de forma que esse novo sistema de coordenadas é dado em ordem decrescente de variância. Sendo assim, é possível selecionar um número de componentes principais fixo e previamente definido a fim de manter uma representatividade satisfatória da variância dos dados e diminuir a dimensionalidade do problema.

Figura 9 - Exemplo ilustrativo PCA.

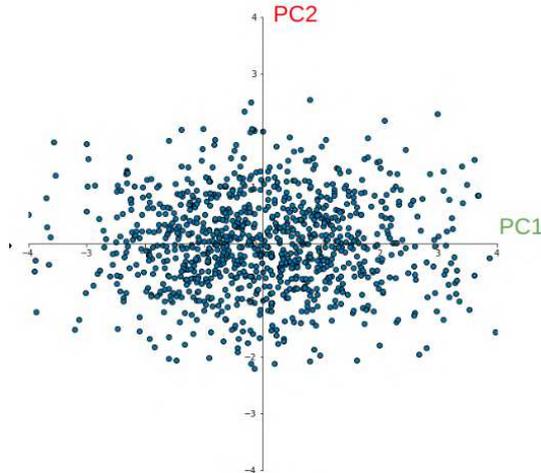
(a) Conjunto de dados expresso no sistemas de coordenadas original.



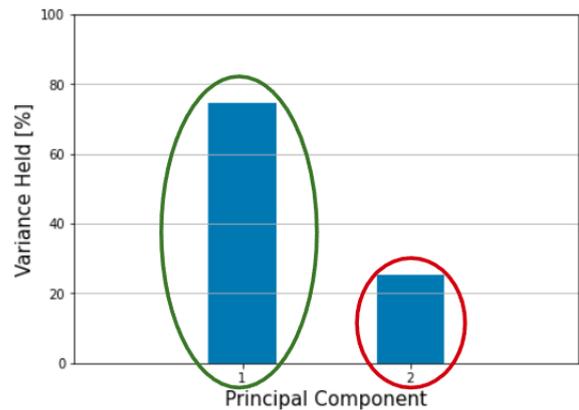
(b) Sistemas de coordenadas original com a direção das componentes principais.



(c) Conjunto de dados expresso no novo sistema de coordenadas.



(d) Porcentagem de variância mantida por cada componente principal.



Fonte: Elaborada pelo autor (2022).

### 3.3.5 Algoritmo de Particionamento de Dados Auto-organizável Ciente de Direção (SODA)

Com o intuito de expressar esse método, devemos considerar o espaço  $J^l$ , proveniente do PCA e assumir a base de dados como  $\{x_1, x_2, x_3, \dots\}$ , em que  $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,l}]^T \in J_l$  é um vetor  $l$ -dimensional,  $i = 1, 2, 3, \dots$ ,  $i(i = 1, 2, 3, \dots)$  indica a instância de tempo pela qual a  $i$ -ésima amostra de dados corresponde. Portanto, no conjunto de dados observados na  $i$ -ésima instância de tempo, denotada por  $\{x_1, x_2, \dots, x_n\}$ , é considerado também o conjunto com a seleção dos valores únicos na amostra de dados  $\{u_1, u_2, \dots, u_{n_u}\}$  ( $u_i = [u_{i,1}, u_{i,2}, \dots, u_{i,l}]^T \in J_l$ ) de  $\{x_1, x_2, \dots, x_n\}$  e o correspondente número de repetições  $\{f_1, f_2, \dots, f_n\}$ , em que  $n_u (1 < n_u \leq n)$  é o número de amostras de dados únicas e

$\sum_{i=1}^{n_u} f_i = 1$ . As passagens seguintes são conduzidas para a  $n$  – ésima instância de tempo como padrão, a não ser que exista uma declaração específica (16).

### 3.3.5.1 Componentes de distância/dissimilaridade

A abordagem SODA emprega (16):

- i uma componente de magnitude baseada em uma métrica tradicional de distância, neste trabalho foi utilizada a distância Euclidiana;
- ii uma componente direcional/angular baseada na dissimilaridade de cosseno do ângulo entre duas amostras;

### 3.3.5.2 Operadores EDA

Os operadores empíricos para análise de dados (EDA - *Empirical Data Analytics*) (16) é uma metodologia alternativa para aprendizado de máquina que é inteiramente baseada em amostrado de dados reais observados empiricamente (17, 18, 19).

Os operadores EDA incluem (16):

#### i. Proximidade Cumulativa(16):

A proximidade cumulativa,  $\pi$  de  $x_i (i = 1, 2, \dots, n)$  é definida como (17, 19):

$$\pi_n(x_i) = \sum_{j=1}^n d^2(x_i, x_j), \quad (3.16)$$

em que  $d(x_i, x_j)$  denota a distância/dissimilaridade entre  $x_i$  e  $x_j$ .

#### ii. Densidade Local (16):

A densidade local  $D$  é definida como o inverso da proximidade cumulativa normalizada e indica diretamente o padrão principal dos dados observados. A densidade local  $D$  de  $x_i (i = 1, 2, \dots, n; n_u > 1)$  é definida como (18, 19):

$$D_n(x_i) = \frac{\sum_{j=1}^n \pi_n(x_j)}{2n\pi_n(x_i)} \quad (3.17)$$

Na abordagem de particionamento de dados proposta, já que ambas as componentes de magnitude e angular são igualmente importantes, a densidade local de  $x_i (i = 1, 2, \dots, n; n_u > 1)$  é definida como a soma da densidade local baseada na componente Euclidiana e a densidade local com base angular.

#### iii. Densidade Global (16):

A densidade global é definida por amostras de dados únicas junto com seu correspondente número de repetições no conjunto total de dados. Ela tem a habilidade

de providenciar distribuições multi-modais automaticamente sem a necessidade de decisões do usuário, procedimentos de busca e otimização ou algoritmos de agrupamento. A densidade global de uma amostra única,  $u_i (i = 1, 2, \dots, n_u; n_u > 1)$  é expressa como o produto de sua densidade local pelo número de repetições, ou seja, um fator de peso (19), como:

$$D_n^G(u_i) = f_i D_n(u_i) \quad (3.18)$$

Como pode ser visto pelas equações acima, os principais operadores EDA: proximidade cumulativa ( $\pi$ ), densidade local ( $D$ ) e densidade global ( $D^G$ ) podem ser atualizados recursivamente, o que mostra que o SODA é modelável para processamento online de dados em tempo real.

### 3.3.5.3 Algoritmo SODA para particionamento de dados

Os passos principais do algoritmo SODA incluem: primeiro, formar planos cientes de direção (DA - *Direction Aware*) das amostras de dados observadas utilizando tanto a densidade baseada no componente de magnitude quanto a angular; em seguida, identificar os pontos focais; finalmente, usar os pontos focais para particionar o espaço em nuvens de dados. O procedimento detalhado do método é descrito a seguir (16).

- **Estágio 1: Preparação (16)**

Nesse estágio, são calculados os operadores EDA para cada amostra de dados únicas  $\{u_1, u_2, \dots, u_{n_u}\}$  tanto para o quadrado da componente Euclidiana,  $d_M$  quanto o quadrado da componente angular,  $d_A$ . Após calcular a densidade global de todas as amostras de dados únicas, elas são ordenadas de forma decendente e renomeadas para  $\{\hat{u}_1, \hat{u}_2, \dots, \hat{u}_{n_u}\}$ .

- **Estágio 2: Projeção dos planos DA (16)**

A operação da projeção dos planos DA começa com a amostra de dados de maior densidade global, nomeada  $\hat{u}_1$ . É definida como sendo a primeira referência,  $\mu_1 \leftarrow \hat{u}_1$ , que também é o ponto de origem do primeiro plano DA, denotado por  $P_1$  ( $L \leftarrow 1$ ,  $L$  é o número de planos DA existentes no espaço). Após todas as amostras únicas serem projetadas em planos DA, o próximo estágio pode começar, mas algumas amostras estão localizadas em mais de um plano DA ao mesmo tempo, então sua afiliação será decidida pelas distâncias entre ela e a origem dos planos DA próximos.

- **Estágio 3: Identificando pontos focais(16)**

Nesse estágio, para cada plano DA, denotado como  $P_e$ , será encontrando o plano DA mais próximo a partir da desigualdade de Chebyshev (19).

É importante mencionar que na desigualdade de Chebyshev é utilizado um parâmetro  $\gamma$ . Este que é o único parâmetro algoritmo SODA definido pelo usuário. Esse parâmetro é relacionado com a sensibilidade do particionamento dos dados, já que para valores maiores de  $\gamma$  implica em valores menores para satisfazer a desigualdade. Por outro lado, também implica que amostras únicas necessitam de ser mais similares para pertencer à um mesmo plano DA. Neste trabalho  $\gamma = 7$  foi usado para a tarefa do particionamento dos dados.

Examinando cada plano DA existente, é encontrado todos os picos de densidade dos dados. Levando em consideração a densidade global calculada no estágio anterior para cada plano DA, um ponto focal descreve a amostra única mais representativa dentro dos limites do plano.

- **Estágio 4: Formando nuvens de dados (16)**

Após os picos de densidade serem identificados para todos os planos DA, estes são considerados como a origem, descritos por  $\{\mu^o\}$ , e são utilizados como pontos focais para a formação de nuvens de dados como um diagrama de Voronoi (66). Vale ressaltar que o conceito de nuvens de dados é muito similar ao conceito de *clusters*, mas é diferente pelos seguintes aspectos: i) nuvens de dados são não-paramétricas; ii) nuvens de dados não tem formato específico; iii) nuvens de dados representam um distribuição real dos dados.

### 3.3.6 Algoritmo de Agrupamento

No Capítulo 1 deste artigo, foi apresentado o algoritmo SODA, uma abordagem não-paramétrica e guiada por dados. Ao utilizar essa técnica, o usuário não interfere diretamente no particionamento dos dados, e o SODA pode dividir os dados em nuvens que não correspondem ao número de grupos entregues à análise do TSFRESH. No entanto, o objetivo do algoritmo é unir as nuvens de dados que retêm informações pertencentes a um mesmo grupo, fornecendo um rótulo para cada amostra contida na nuvem. Ao final do processo, as nuvens são agrupadas em três categorias: ferramenta em condição adequada (índice = 0), ferramenta em condição intermediária (índice = 1) e ferramenta em condição inadequada (índice = 2), conforme apresentado no Capítulo 2.

A saída do SODA é um vetor com dimensão equivalente ao número de séries temporais na base de dados, contendo um índice correspondente à nuvem de dados a que a série temporal pertence. Em seguida, a porcentagem de dados pertencentes a cada grupo em cada nuvem é calculada como um parâmetro de condição no algoritmo de agrupamento. Se uma nuvem de dados contém mais de 50% das amostras pertencentes a um grupo específico, o algoritmo rotula essas amostras com o índice correspondente a esse grupo.

Os principais objetivos desse algoritmo são reduzir a interferência humana no processo e otimizar o número de grupos a serem considerados durante a classificação. O algoritmo de agrupamento combina tanto os grupos dados pelo especialista quanto os grupos identificados pelo SODA, levando em conta as propriedades não-paramétricas e guiadas por dados das nuvens de dados. Dessa forma, é possível obter o número ótimo de grupos para a classificação das ferramentas em diferentes condições.

## 4 RESULTADOS

Neste capítulo será apresentada a base de dados e a forma como foi coletada. Será apresentada uma análise comparativa entre a base de dados e realizações simuladas do processo estocástico que representa o motor de giro do torno, essa análise do processo tem o objetivo de validar o protótipo de aquisição de dados e mostrar a estacionaridade e ergodicidade do processo. E finalmente, também neste capítulo será apresentado os resultados do modelo de classificação multiclasse. Os algoritmos utilizados na realização deste trabalho podem ser encontrados em <https://github.com/mmaltafe/LAIIC-PPE-E-Modelo-Ferramentas-de-Corte>.

### 4.1 BASE DE DADOS

A base de dados utilizada neste trabalho é composta por 785 séries temporais normalizadas da tensão e corrente de cada uma das três fases do motor do torno utilizando o protótipo apresentado na Seção 3.1. O processo de aquisição de dados é feito em uma taxa de amostragem de 24 kHz. Cada série temporal é composta por 3584 amostras. É importante ressaltar que dessas séries temporais 552 estão relacionadas a uma ferramenta em condição adequada, 80 relacionadas com uma ferramenta em condição intermediária e 153 a uma em condição inadequada. A estrutura do conjunto de dados é apresentada na Tabela 1. Embora na tabela esteja presente as séries temporais de tensão, como foi dito no Capítulo 2 será utilizado no modelo somente as leituras de corrente.

ID	Amostra	Tensão A (V)	Tensão B (V)	Tensão C (V)	Corrente A (A)	Corrente B (A)	Corrente C (A)
1	1	1.91	-0.74	-0.50	-0.52	0.43	-1.03
1	2	1.06	-1.76	-0.37	-1.12	0.45	1.17
...	...	...	...	...	...	...	...
1	3584	0.48	-0.22	-0.24	-0.33	0.95	-1.69
2	1	0.78	-0.22	-0.36	0.16	-0.06	1.45
2	2	-0.21	-0.74	-0.24	-1.18	1.09	0.46
...	...	...	...	...	...	...	...
2	3584	-1.18	0.79	0.24	1.65	-0.09	-0.09
...	...	...	...	...	...	...	...
785	1	-0.85	0.28	2.81	-0.74	-2.15	0.07
785	2	-1.18	0.79	-0.37	0.56	-1.21	0.64
...	...	...	...	...	...	...	...
785	3584	-0.83	1.82	-0.56	1.52	0.60	-0.97

Tabela 1 – Representação da Entrada de Dados do Modelo.

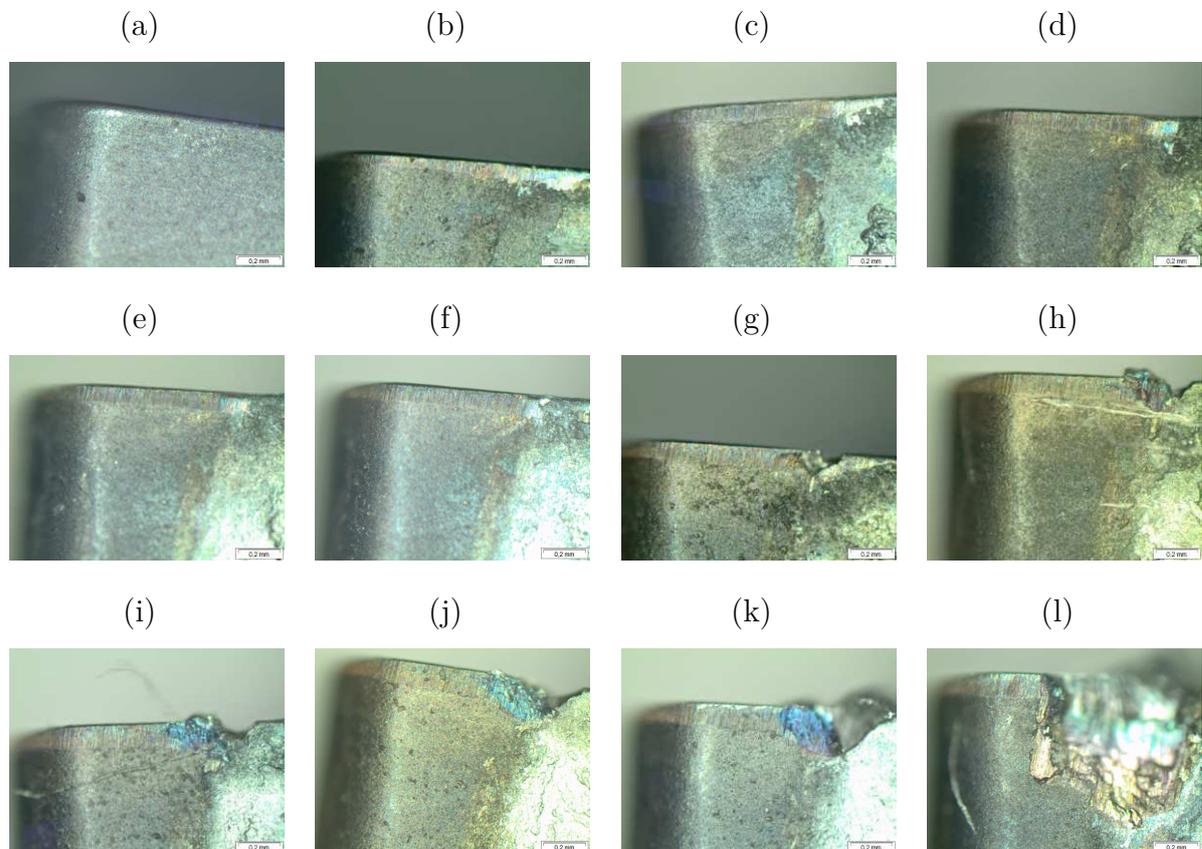
O procedimento para o processo de aquisição de dados utilizado neste trabalho foi descrito no Capítulo 2. O mesmo consiste em executar sucessivos passes de usinagens e examinar em intervalos regulares a condição de desgaste da ferramenta. Este processo é repetido até que o desgaste da ferramenta atinja um limite pré-estabelecido de  $0,6mm$ . Com uma profundidade de corte de  $0,5mm$  foi estabelecido que a cada 10 passes com a ferramenta ela seria retirada e analisada no microscópio, um detalhamento desse processo pode ser

visto na Tabela 2. Dessa forma o desgaste da ferramenta pode ser visto gradativamente na Figura 10.

Condição da Ferramenta	Número de Séries Temporais no Passe	Diâmetro Inicial da Peça Usinada [mm]	Diâmetro Final da Peça Usinada [mm]	Figura Correspondente
Adequada	65	76	66	10a
Adequada	108	66	56	10b
Adequada	55	56	46	10c
Adequada	40	46	36	10d
Adequada	27	36	26	10e
Adequada	134	76	66	10f
Adequada	66	66	56	10g
Adequada	57	56	46	10h
Intermediária	44	46	36	10i
Intermediária	36	36	26	10j
Inadequada	143	68	58	10k
Inadequada	10	58	56	10l

Tabela 2 – Descritivo do Procedimento de Aquisição de Dados.

Figura 10 - Evolução do Desgaste de Flanco na Ferramenta



Fonte: Elaborada pelo autor (2022).

## 4.2 ANÁLISE DO PROCESSO ESTOCÁSTICO

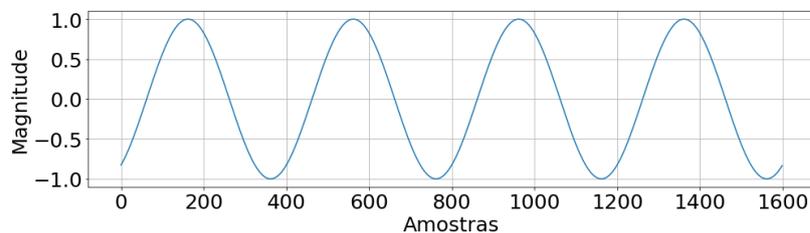
O valor esperado para  $X(t)$  é a média sobre o conjunto de realizações. Para calcular  $R_{XX}(\tau)$  ou  $\mu_{X(t)}$  é necessário conhecer a PDF ou ter varias realizações do processo.

A partir das realizações práticas de um processo estocástico é possível obter a sua caracterização parcial, isto é, conhecer suas funções média e autocorrelação.

### 4.2.1 Simplificação Matemática

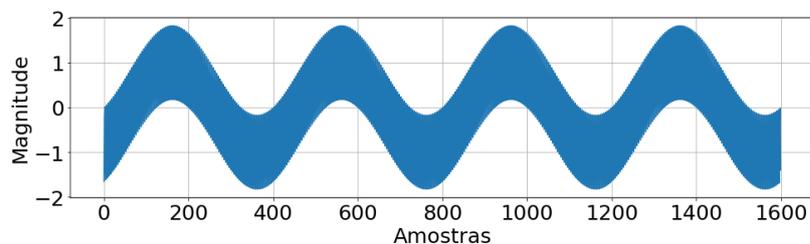
As séries temporais utilizadas neste trabalho, aquisitadas no motor trifásico do torno podem ser decompostas em uma senoide com frequência de 60 Hz proveniente da rede, uma segunda componente senoidal com frequência de 6 kHz proveniente do inversor de frequências do motor de giro do torno e um ruído aleatório que pode ser simulado como um ruído gaussiano branco (AWGN - Additive White Gaussian Noise). Como as series temporais são normalizadas ao decorrer do processo, as séries apresentam amplitude unitária. A decomposição do processo pode ser vista nas Figuras 11, 12 e 13. A fim de facilitar a visualização por parte do leitor os sinais são exibidos ao decorrer do trabalho em formato contínuo.

Figura 11 - Componente Senoidal de 60Hz.



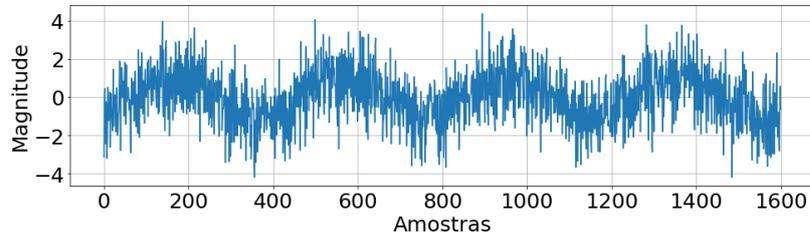
Fonte: Elaborada pelo autor (2022).

Figura 12 - Componente Senoidal de 60 Hz com Adição da Componente de 6 kHz.



Fonte: Elaborada pelo autor (2022).

Figura 13 - Componente Senoidal de 60 Hz com Adição da Componente de 6 kHz e Ruído Gaussiano Branco.



Fonte: Elaborada pelo autor (2022).

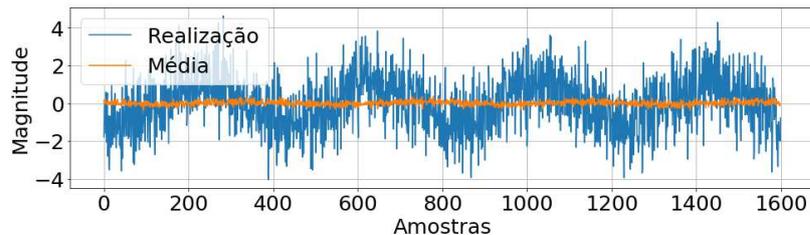
As simplificações foram geradas com 1600 amostras, numa taxa de amostragem de 24 kHz, contendo então 4 ciclos completos da senoide de 60 Hz. Dessa forma 400 amostras compreendem um ciclo de 60 Hz e 4 amostras um ciclo de 6 kHz. Como as aquisições não são sincronizadas, também é adicionada uma fase uniforme aleatória  $[0, 2\pi)$  nas senoídes.

As caracterizações do sinal de exemplo foram feitas levando em consideração 100 realizações do processo.

#### 4.2.1.1 Média

Para o cálculo da média foi utilizado a Equação 3.2. A média para cada instante de tempo pode ser vista na Figura 14. Na imagem também pode ser visto o exemplo de uma realização.

Figura 14 - Média do Processo Senoidal.



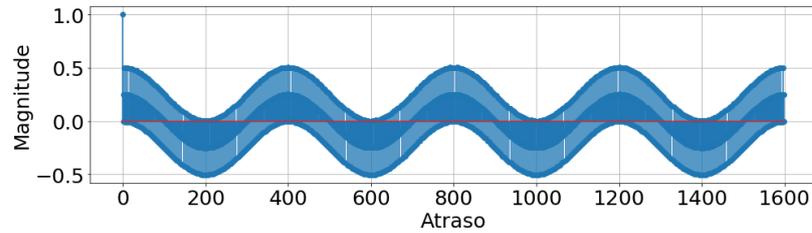
Fonte: Elaborada pelo autor (2022).

Conforme a imagem demonstra, a média do processo pode ser aproximada para uma constante  $\mu_{X(t)} = 0$  para todo  $t$ . Mostrando então que a média não depende do tempo e garantindo uma estacionariedade de 1ª ordem para o processo.

#### 4.2.1.2 Autocorrelação

Para o cálculo da autocorrelação do processo, foi utilizada a Equação 3.5, foi calculada a autocorrelação para todas as realizações do processo com atrasos entre  $[0, 1600]$  e foi feita a média para cada atraso levando em consideração todas as realizações. A Figura 15 mostra a função de autocorrelação do processo.

Figura 15 - Autocorrelação do Processo Senoidal.

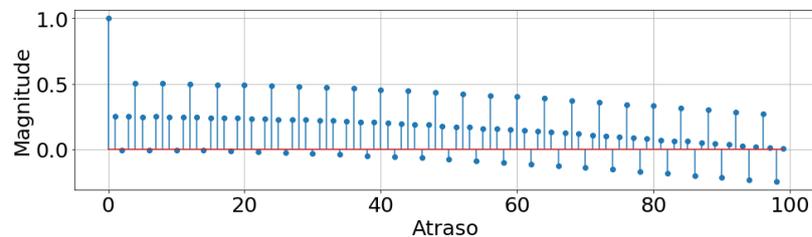


Fonte: Elaborada pelo autor (2022).

Como é possível notar com essa visualização geral da função de autocorrelação, a autocorrelação do processo demonstra um comportamento senoidal. Olhando com detalhe é possível observar que os pontos de máximo na autocorrelação, além do atraso igual a 0, estão próximos do atraso de 400, 800, 1200 e 1600 amostras. Esses pontos descrevem o ciclo da senoide de 60 Hz, portanto notamos que mesmo com o comportamento ruidoso do sinal a frequência da rede ainda aparece na autocorrelação.

Além do comportamento oscilatório de 60 Hz na autocorrelação, podemos notar também um sombreamento ao decorrer da função. Na Figura 16 temos uma ampliação nos 100 primeiros atrasos da função de correlação para analisar esse comportamento.

Figura 16 - Autocorrelação do Processo Senoidal - 100 atrasos.



Fonte: Elaborada pelo autor (2022).

Como é possível notar pela Figura 16 o sombreamento na função é dado por oscilações em um período de 4 amostras, facilmente explicado pela componente senoidal de 6 kHz proveniente do inversor de frequências do motor do torno.

Podemos notar então que se trata de um processo ciclo-estacionário, ou seja, um processo estocástico que exhibe ciclos ou variações periódicas em sua média e/ou autocovariância ao longo do tempo. Em outras palavras, o comportamento do processo repete-se de forma semelhante em intervalos regulares de tempo.

#### 4.2.2 Processo Aquisitado do Motor do Torno

As séries temporais reais do processo de usinagem foram adquiridas com uma taxa de amostragem de 24 kHz e cada série contém 3584 amostras. Entretanto, esse valor foi

reduzido na etapa de análise do processo estocástico para facilitar a implementação, o valor 1600 foi escolhido para manter um número completo de 4 ciclos da senoide de 60 Hz nas realizações. Portanto o sinal é truncado e as últimas amostras são retiradas. Como o sinal é periódico, truncar essas amostras não afetará as análises.

Foram realizados ensaios sucessivos com uma mesma ferramenta durante toda sua vida útil. Os ensaios resultaram em 552 realizações com a ferramenta em condição adequada de operação, 80 realizações em estágio intermediário e 153 ensaios em condição inadequada de operação segundo a norma ISO 3685/1993.

Cada análise realizada será feita para as três classes de ferramenta e para as três fases da corrente do motor, resultando num total de nove processos a serem analisados separadamente.

#### 4.2.2.1 Média

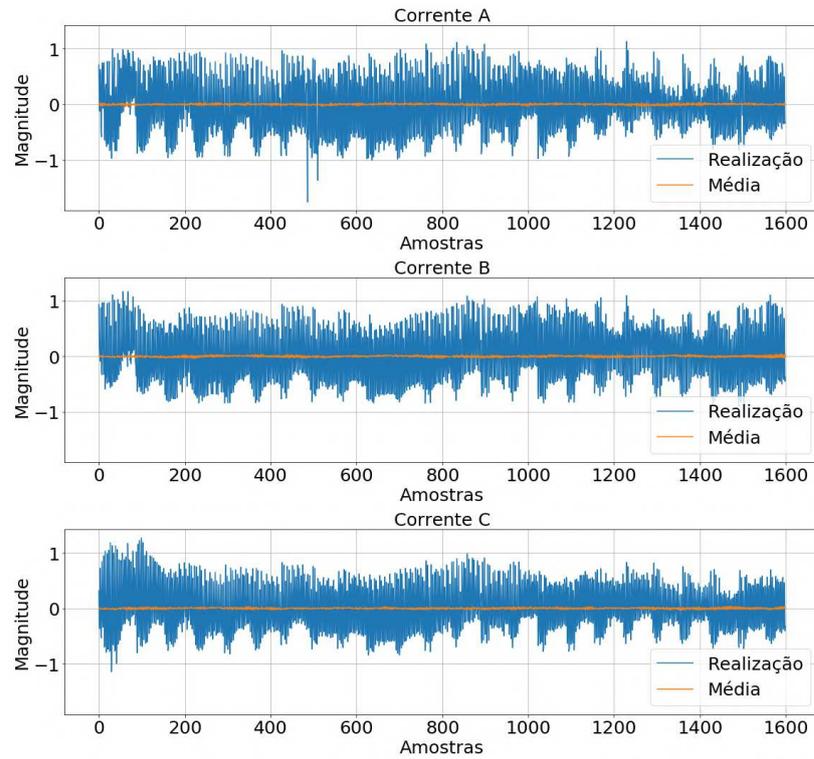
A média do processo é calculada segundo a Equação 3.2. É possível notar pelas Figuras 17, 18 e 19 que representam as médias para a condição adequada, intermediária e inadequada respectivamente.

Nas imagens também pode ser visto o exemplo de uma realização para exemplificar cada um dos casos. Diferentemente do observado na Figura 14 na qual mesmo com o ruído era fácil observar a oscilação senoidal de 60 Hz na série temporal, as realizações reais apresentam um comportamento mais ruidoso.

Ainda nas Figuras 17, 18 e 19 podemos notar que para as três fases nos três casos a média se aproxima de uma constante  $\mu = 0$ . Vale ressaltar que um comportamento mais próximo de uma constante é visto para a ferramenta em condição adequada, isso se deve ao fato de que essa classificação apresenta um número muito maior de realizações do que os outros dois casos. Pelo motivo inverso, a ferramenta em condição intermediária apresentar um número menor de realizações, esta então apresenta uma variação um pouco maior na média do processo.

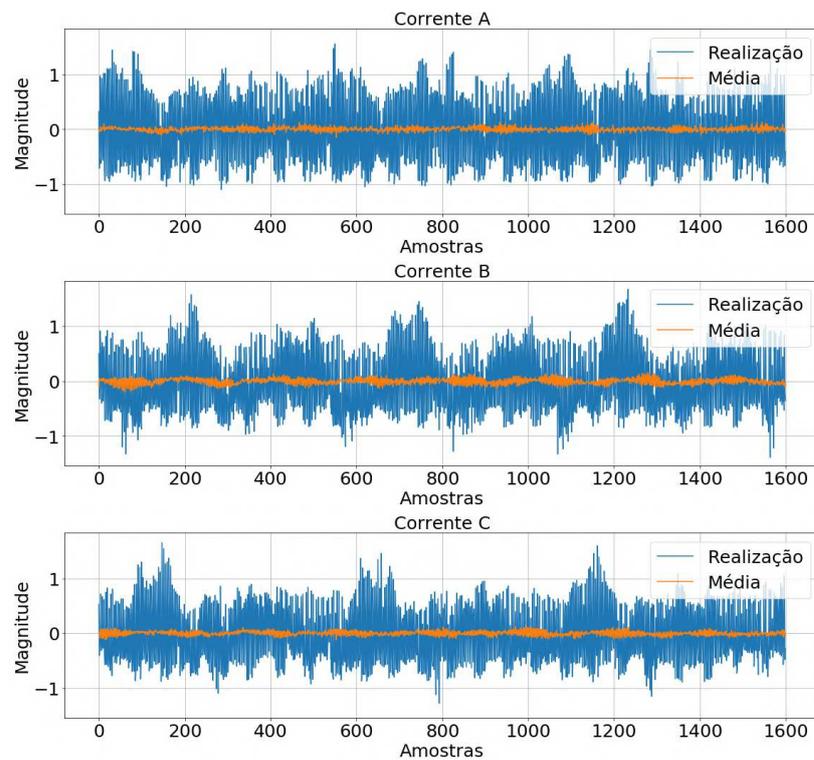
Como todos os nove processos apresentam uma média aproximadamente constante, podemos dizer que os processos apresentam estacionariedade de primeira ordem. Assim como o processo gerado na Seção 4.2.1.

Figura 17 - Média do Processo Real - Ferramenta Adequada.



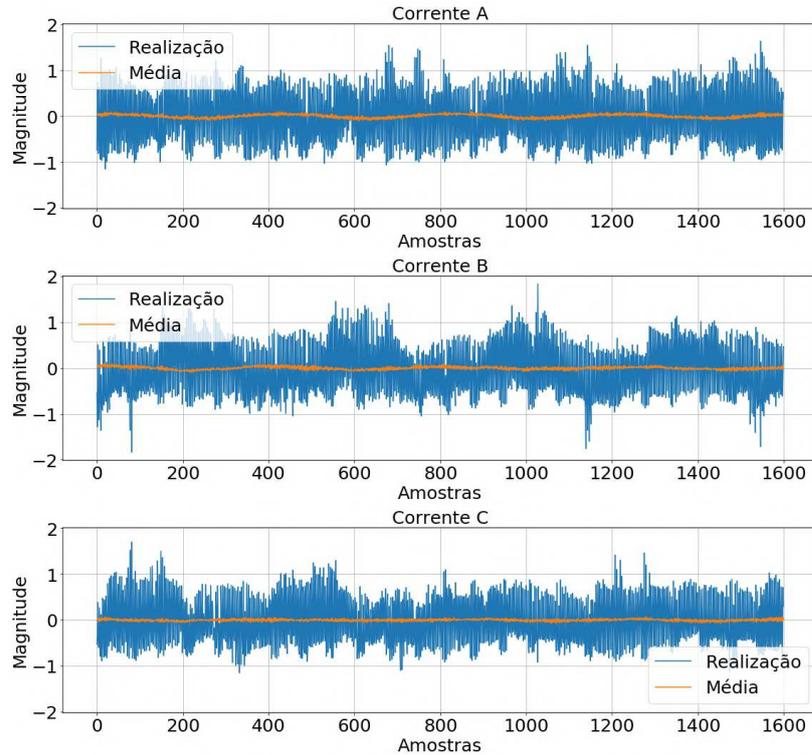
Fonte: Elaborada pelo autor (2022).

Figura 18 - Média do Processo Real - Ferramenta Intermediária.



Fonte: Elaborada pelo autor (2022).

Figura 19 - Média do Processo Real - Ferramenta Inadequada.



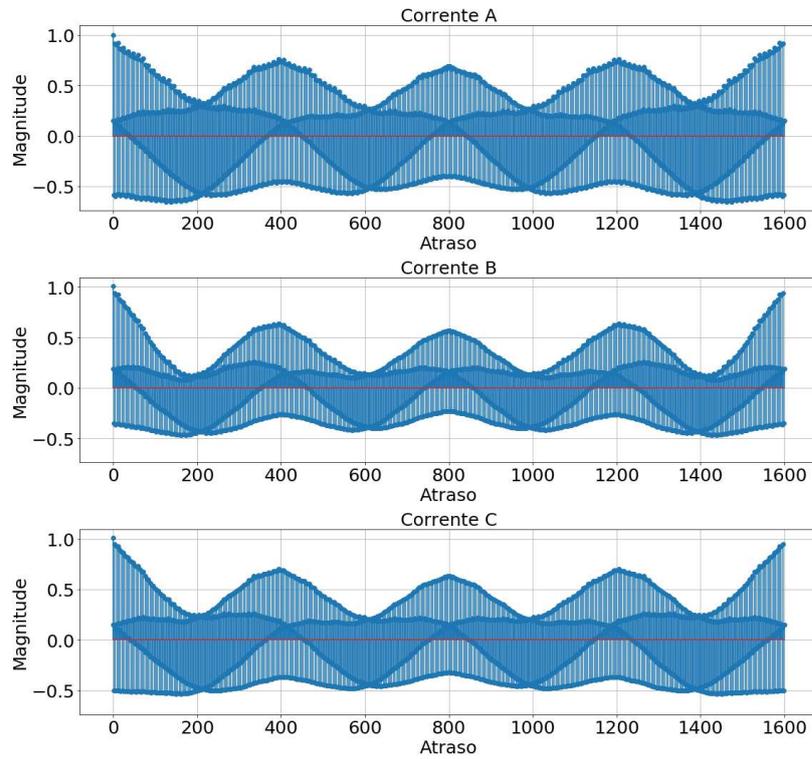
Fonte: Elaborada pelo autor (2022).

#### 4.2.2.2 Autocorrelação

Para o cálculo da autocorrelação foi usada a estimação mostrada na Equação 3.5. Foi calculada a estimação para todas as realizações de um determinado processo com atrasos entre  $[0, 1600]$  e para cada um dos nove processos foi calculado o valor médio da função de autocorrelação para cada atraso dentro do intervalo. Os resultados são exibidos nas Figuras 20, 21 e 22 para condição adequada, intermediária e inadequada respectivamente.

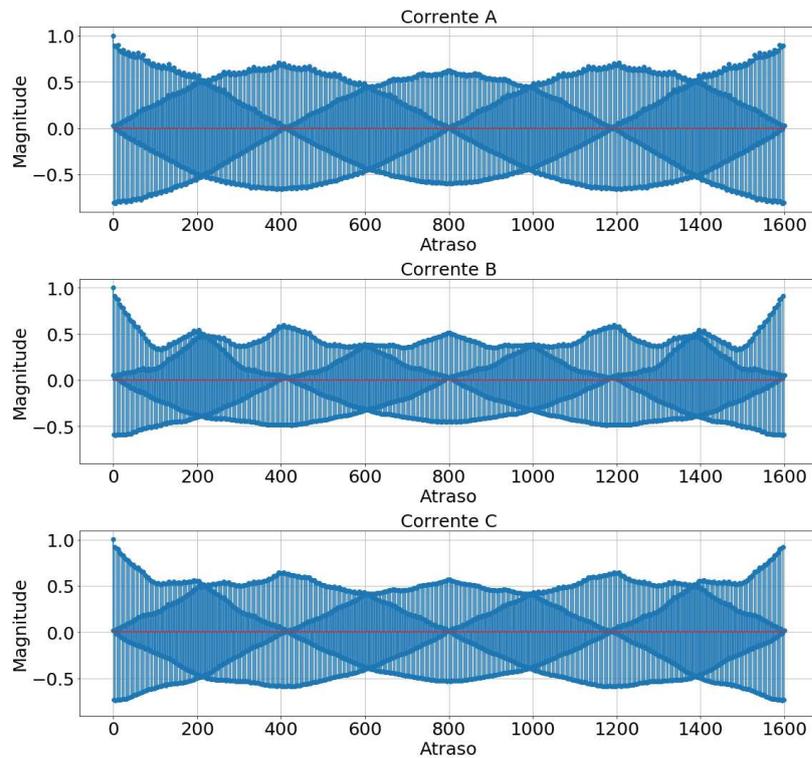
Assim como foi visto para a simplificação matemática do processo na Seção 4.2.1. Existe uma certa periodicidade na função de autocorrelação das correntes para todos os nove casos. O mesmo comportamento de picos na autocorrelação para os atrasos de 400, 800, 1200 e 1600 é visto também nos sinais de corrente, mostrando que mesmo sendo realizações bastante ruidosas ainda existe uma importante colaboração da componente oscilatória de frequência de 60 Hz.

Figura 20 - Autocorrelação do Processo Real - Ferramenta Adequada.



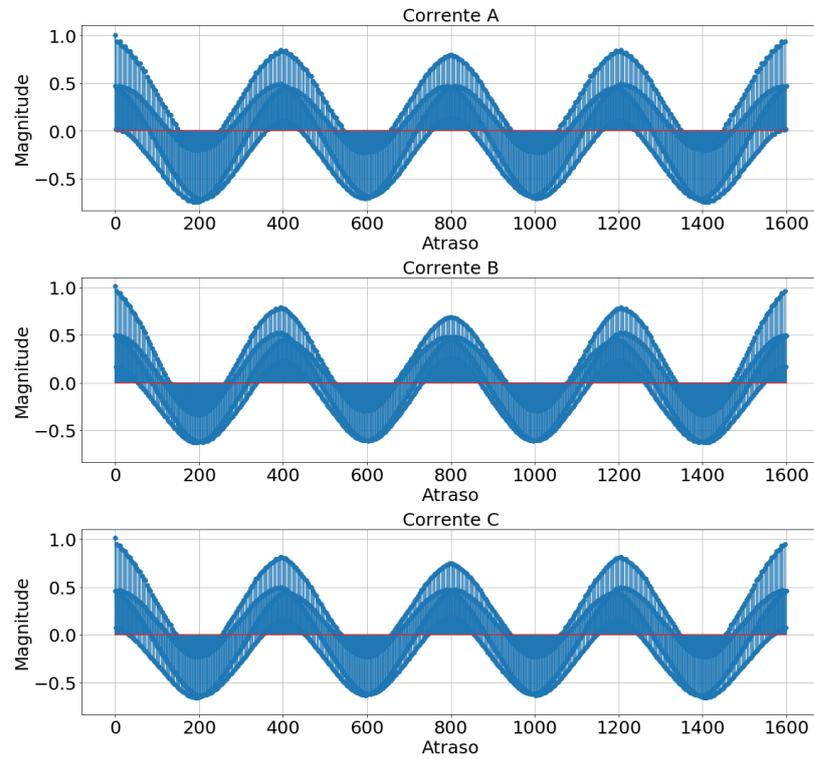
Fonte: Elaborada pelo autor (2022).

Figura 21 - Autocorrelação do Processo Real - Ferramenta Intermediária.



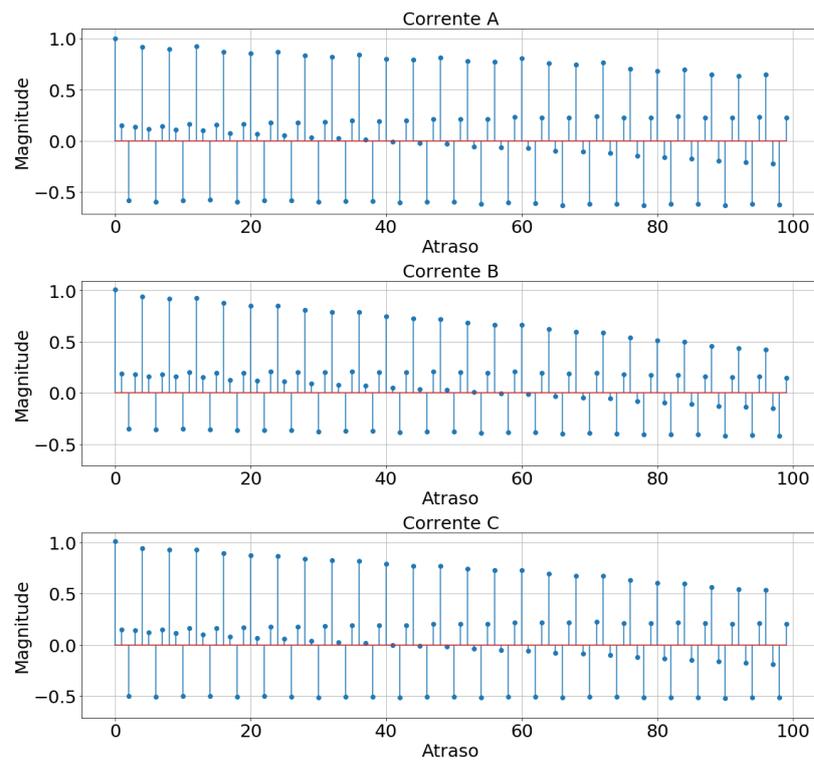
Fonte: Elaborada pelo autor (2022).

Figura 22 - Autocorrelação do Processo Real - Ferramenta Inadequada.



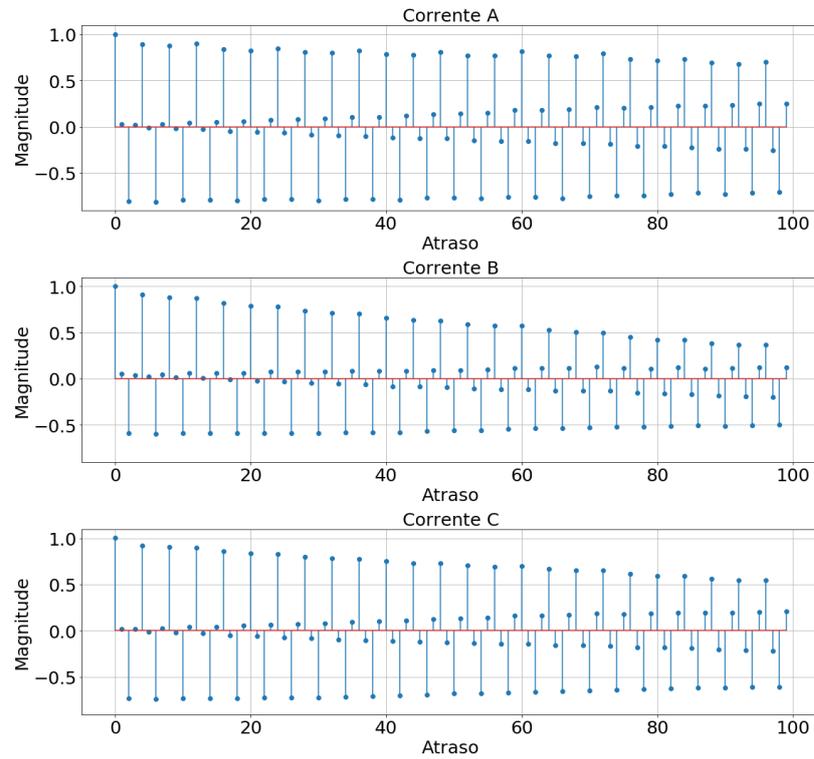
Fonte: Elaborada pelo autor (2022).

Figura 23 - Autocorrelação do Processo Real - Ferramenta Adequada.



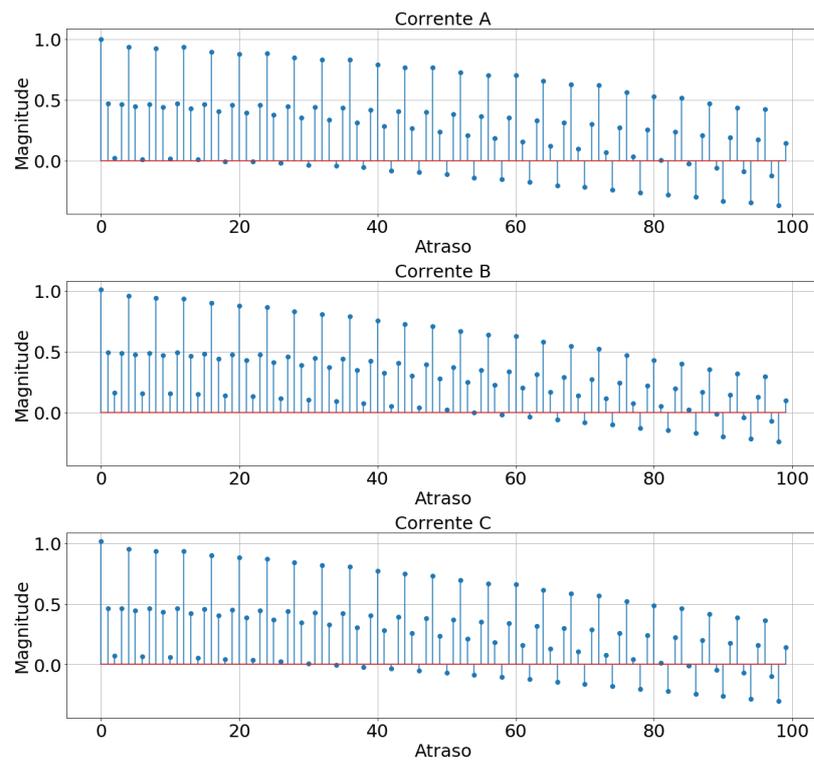
Fonte: Elaborada pelo autor (2022).

Figura 24 - Autocorrelação do Processo Real - Ferramenta Intermediária.



Fonte: Elaborada pelo autor (2022).

Figura 25 - Autocorrelação do Processo Real - Ferramenta Inadequada.



Fonte: Elaborada pelo autor (2022).

Um detalhe importante que aparece tanto na função de autocorrelação do processo real quanto do processo simplificado é o sombreamento no decorrer da função. As Figuras 23, 24 e 25 apresentam a função de autocorrelação com uma ampliação nos 100 primeiros atrasos. Novamente para os nove casos é possível observar uma periodicidade a cada 4 amostras. Comportamento explicado pela frequência de disparo do inversor presente no motor do torno.

Outro comportamento importante que pode ser observado é a diferença na função de autocorrelação para as três condições da ferramenta, embora em um panorama geral elas apresentem o mesmo caráter oscilatório, visualmente existe uma diferença entre os processos. Uma forma de observarmos essa diferença é pela densidade espectral de potência, mas para isso primeiro é necessário demonstrar a ergodicidade do processo em seu sentido amplo.

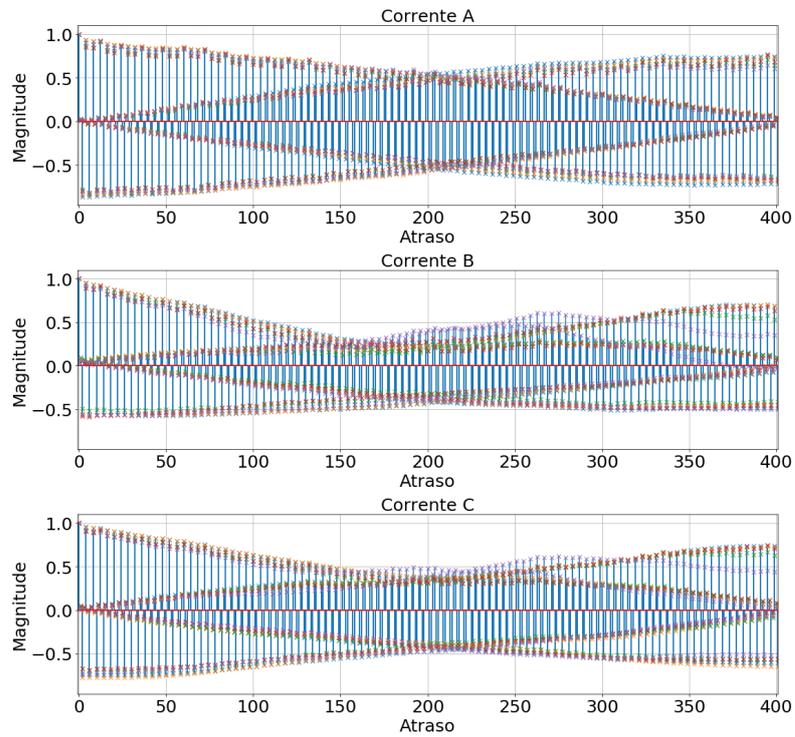
#### 4.2.2.3 *Ergodicidade*

Para demonstrar a ergodicidade do processo em seu sentido amplo, é necessário verificar se seus momentos estatísticos, calculados ao longo de várias realizações do processo, são equivalentes aos momentos temporais, calculados a partir de uma única realização do processo. Os cálculos de autocorrelação são feitos segundo a estimativa apresentadas na Equação 3.5 respectivamente.

As Figuras 26, 27 e 28 representam a autocorrelação de cinco realizações dos processos sobrepostas para um atraso indo de 0 até 400 amostras para condição adequada, intermediária e inadequada respectivamente.

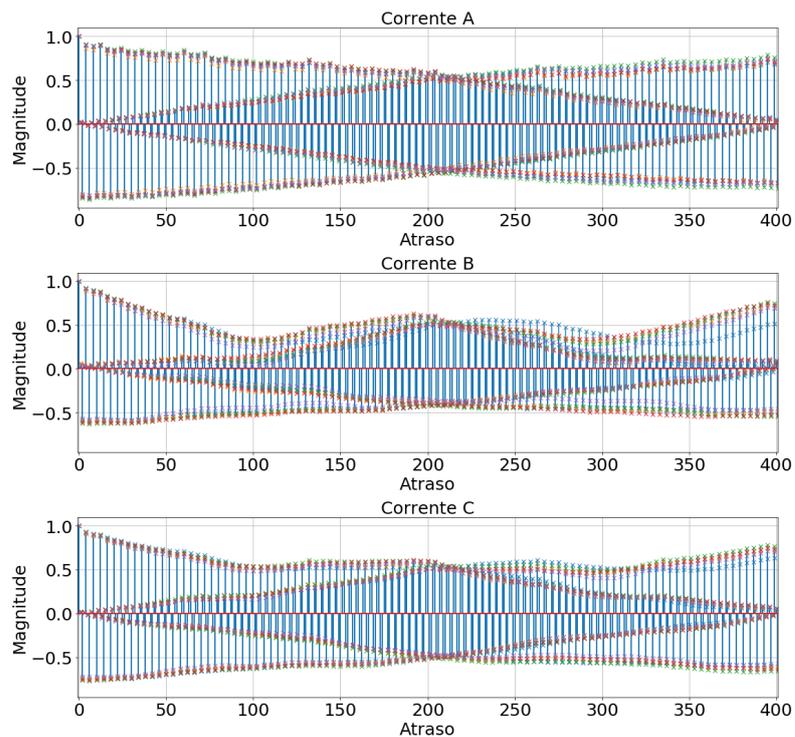
É possível observar que mesmo observando somente as cinco realizações os processos continuam apresentando uma função de autocorrelação com caráter oscilatório semelhante ao encontrado nas Figuras 20, 21 e 22 que representam as médias da função de autocorrelação para condição adequada, intermediária e inadequada da ferramenta respectivamente. Portanto, para fins de simplificação podemos assumir que o processo é ergódico no sentido amplo.

Figura 26 - Função de Autocorrelação para 5 Realizações do Processo - Ferramenta Adequada.



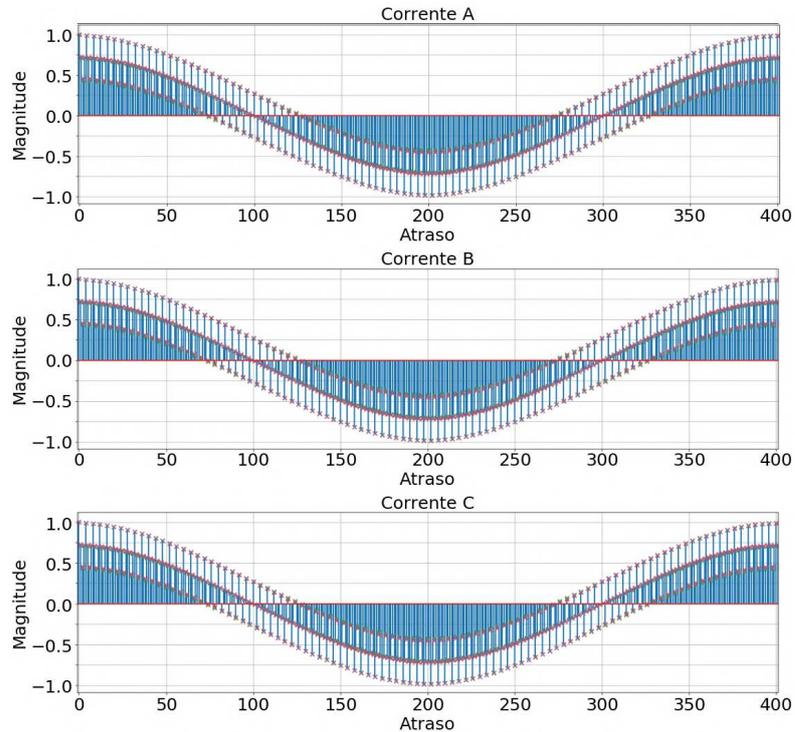
Fonte: Elaborada pelo autor (2022).

Figura 27 - Função de Autocorrelação para 5 Realizações do Processo - Ferramenta Intermediária.



Fonte: Elaborada pelo autor (2022).

Figura 28 - Função de Autocorrelação para 5 Realizações do Processo - Ferramenta Inadequada.



Fonte: Elaborada pelo autor (2022).

Dizer que um processo estocástico é ergódico no sentido amplo implica em assumir que podemos inferir todas as informações estatísticas sobre o processo estocástico a partir de uma única realização do mesmo.

#### 4.2.2.4 Densidade Espectral de Potência

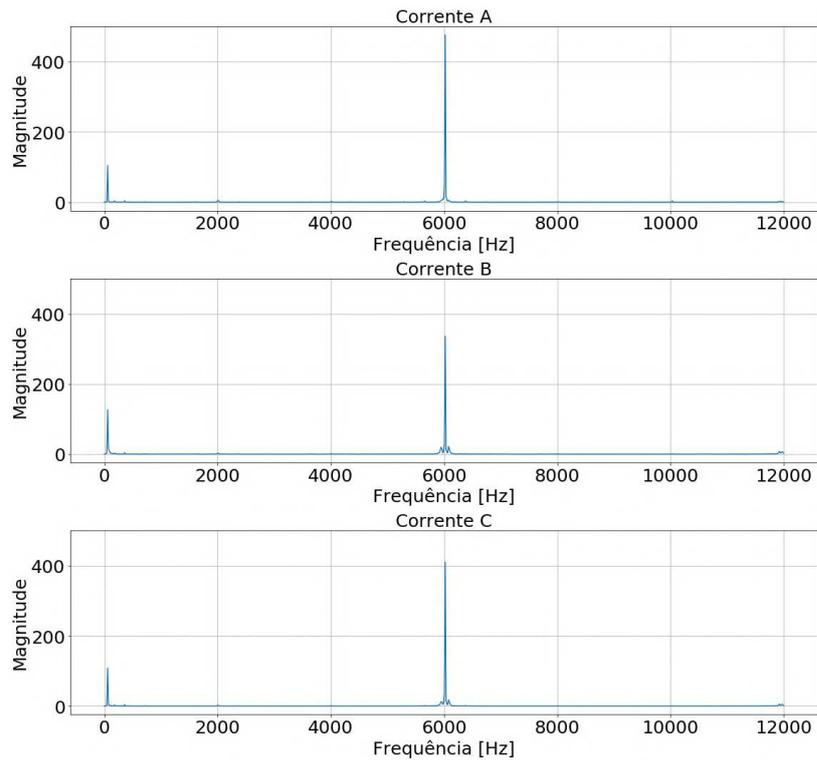
Após garantir a ergodicidade em sentido amplo do processo é possível estimar a densidade espectral de potência através FFT da estimativa da função de autocorrelação, conforme mostra a Equação 3.7. As Figuras 29, 30 e 31 mostram a magnitude da densidade espectral de potência para a ferramenta em condição adequada, intermediária e inadequada respectivamente.

A densidade espectral de potência é um indicador da distribuição da potência do sinal como uma função da frequência. A partir do gráfico temporal foi possível ter alguma noção de quais frequências carregam informação por se tratar de um processo conhecido, mas ao observarmos a densidade espectral de potência é possível ver claramente um impulso presente na frequência de 6 kHz, referente ao inversor de frequências, para as três condições de operação, além da presença de uma componente de 60 Hz, referente à alimentação da rede.

Como havia sido observado anteriormente, para as três condições de operação da

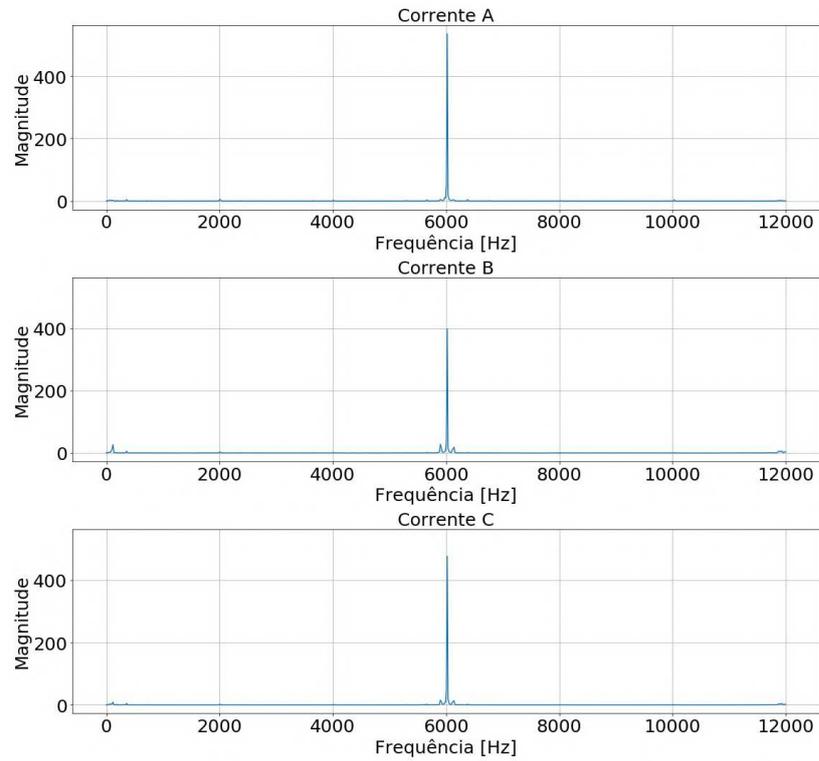
ferramenta havia uma diferença no caráter oscilatório. Essa diferença se mostra bem acentuada na densidade espectral de potência, em que para a ferramenta em condição inadequada de operação é visível uma componente com alta potência em 60 Hz, para a condição adequada de funcionamento essa componente aparece com menor magnitude, já para a ferramenta em condição intermediária a componente de 60 Hz quase não se encontra presente.

Figura 29 - Densidade Espectral de Potência - Ferramenta Adequada



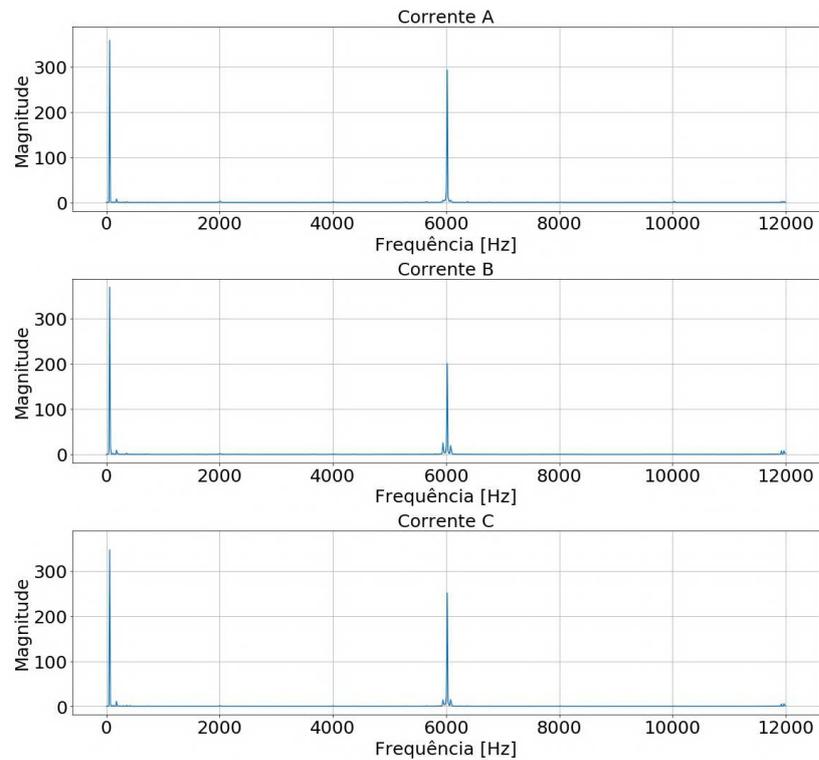
Fonte: Elaborada pelo autor (2022).

Figura 30 - Densidade Espectral de Potência - Ferramenta Intermediária.



Fonte: Elaborada pelo autor (2022).

Figura 31 - Densidade Espectral de Potência - Ferramenta Inadequada.



Fonte: Elaborada pelo autor (2022).

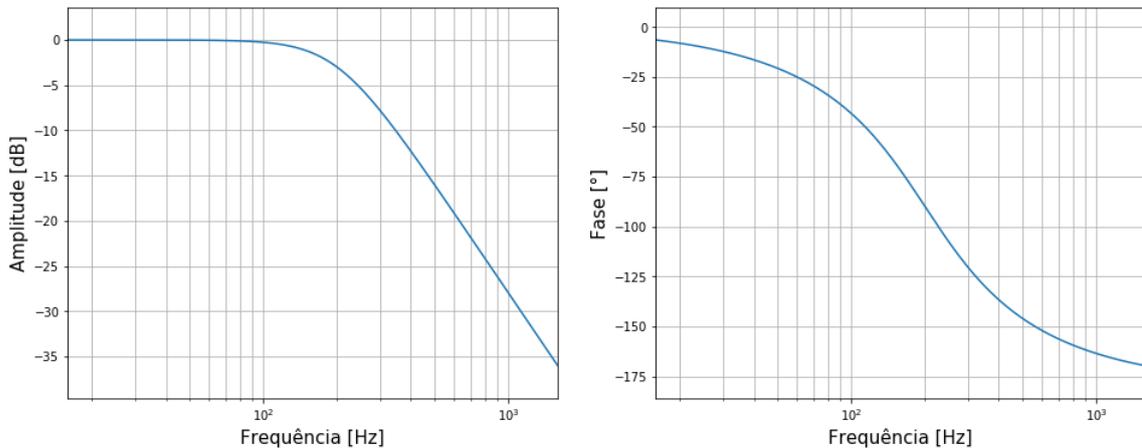
### 4.3 CLASSIFICAÇÃO

Nessa seção, todos os algoritmos foram executados em um computador com processador Intel Core i7-8565U, frequência de *clock* de  $4,60GHz$  e  $12GB$  de RAM. Com o objetivo de garantir robustez nos resultados, foi implementado o método de validação cruzada *K-Fold* utilizando 5 dobras para evitar desbalanceamento nas partições de treino e validação e para que cada partição tenha tamanho suficiente para representar adequadamente a distribuição dos dados(67).

Primeiramente, foi aplicado às séries temporais um filtro de Butterworth passa baixa de segunda ordem e frequência de corte de  $200Hz$  para manter a frequência da rede ( $60Hz$ ) e eliminar as componentes de alta frequência, principalmente a frequência de disparo do inversor. A Equação 4.1 descreve a equação do filtro aplicado nas séries temporais. O diagrama de Bode do filtro pode ser visto na Figura 32.

$$G(s) = \frac{1,58 \times 10^6}{s^2 + 1,78 \times 10^3s + 1,58 \times 10^6} \quad (4.1)$$

Figura 32 - Diagrama de Bode do Filtro Butterworth passa baixa de segunda ordem



Fonte: Elaborada pelo autor (2022).

O algoritmo TSFRESH foi utilizado como solução para a etapa de seleção/extração de atributos desse trabalho. Como foi apresentado na Seção **3.3.3** os atributos são extraídos com parâmetros diferentes. A seleção de atributos depende fortemente dos padrões de dados do subconjunto de treinamento. Portanto, o número de atributos extraídos pode diferir ao longo da validação cruzada.

A seleção de atributos resultou em média em 754 atributos relevantes usando a estratégia de união e 257 atributos relevantes usando a estratégia de interseção para cada série temporal. Vale ressaltar que essas estratégias foram apresentadas na Seção **3.3.3**. Em seguida, o método PCA foi aplicado aos dados de saída do TSFRESH visando reduzir sua dimensionalidade. Devido ao fato de que o uso de mais componentes não aumentaria

significativamente a informação mantida as primeiras 15 PCs foram utilizadas, mantendo 92,86% da variância dos dados.

O SODA (16) dividiu os dados em 8 nuvens de dados. O algoritmo de agrupamento, exposto na Seção 3.3.6, dividiu essas nuvens em grupos da seguinte forma: nuvens de ferramentas de condições adequadas, nuvens de ferramentas de condições intermediárias, nuvens de ferramentas de condições inadequadas. Os dados foram rotulados de acordo com esta divisão. Os subconjuntos de treino e teste foram divididos usando validação cruzada K-Fold com 5 dobras. Para fins de comparação, a classificação foi executada com união e interseção na seleção de atributos fornecida pelo TSFRESH. Os resultados da classificação para cada caso são apresentados na Tabela 3.

Considerando a Tabela 3, para a maioria dos classificadores, a estratégia de união de características resulta em maior precisão do que a estratégia de interseção. Por outro lado, a estratégia de união dobra o tempo de execução do algoritmo. Conseqüentemente, o ganho de precisão não justifica o uso da união de características. É possível notar também que o limitante de tempo no modelo proposto não é relacionado com os classificadores e sim com a técnica de extração de atributos utilizada.

Tabela 3 – Acurácia dos Classificadores

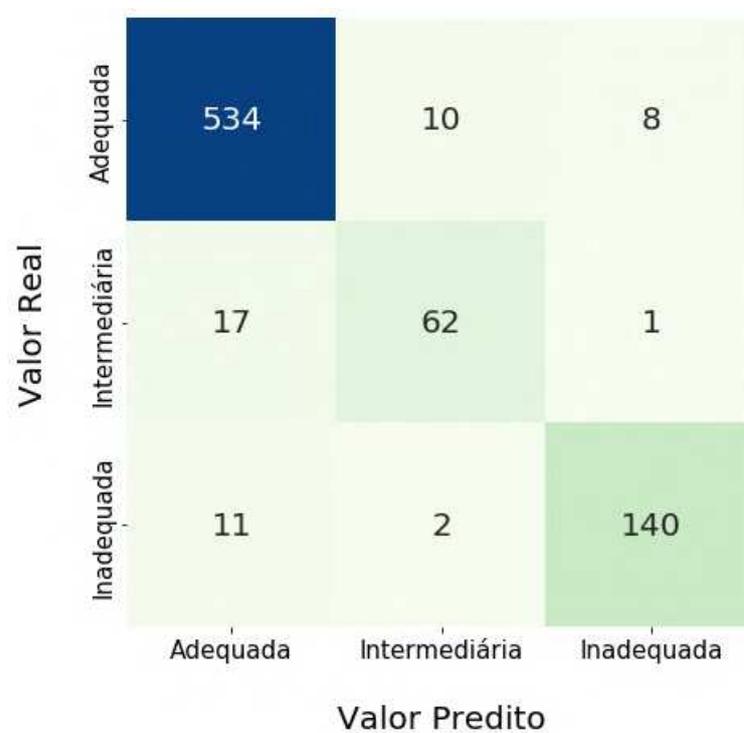
Classificador	Acurácia Balanceada[%]		Tempo [min]	
	União	Interseção	União	Interseção
AdaBoost	61.87 ± 8.28	63.95 ± 9.05	3:03.2043 ± 0:33.0637	1:02.5893 ± 0:18.4183
Decision Tree	79.00 ± 2.58	79.57 ± 5.59	3:03.1967 ± 0:33.0634	1:02.5814 ± 0:18.4180
Linear SVM	80.52 ± 6.16	76.21 ± 5.23	3:03.1977 ± 0:33.0634	1:02.5826 ± 0:18.4180
Gaussian Naive Bayes	84.42 ± 4.98	75.39 ± 6.64	3:03.1967 ± 0:33.0635	1:02.5816 ± 0:18.4182
Nearest Neighbors	83.15 ± 3.30	79.71 ± 4.27	3:03.2035 ± 0:33.0638	1:02.5884 ± 0:18.4183
MLP Neural Network	88.58 ± 4.85	88.87 ± 4.57	3:03.1967 ± 0:33.0634	1:02.5816 ± 0:18.4180
Quadratic Discriminant Analysis	89.44 ± 2.90	83.72 ± 4.41	3:03.1969 ± 0:33.0635	1:02.5815 ± 0:18.4181
Random Forest	81.28 ± 5.49	79.69 ± 4.03	3:03.2068 ± 0:33.0638	1:02.5918 ± 0:18.4180

Os classificadores implementados neste trabalho são baseados na biblioteca *Scikit-Learn* (68), uma biblioteca focada em inteligência computacional em Python. Foram selecionados classificadores clássicos da literatura de forma a demonstrar que o todo método de pré-processamento do modelo a partir da extração e seleção de atributos, redução de dimensionalidade e clusterização garante robustez na classificação mesmo sem se aprofundar na construção de classificadores mais complexos. Mesmo com outras configurações para os classificadores tendo sido testadas, a acurácia máxima foi obtida utilizando as configurações apresentadas no exemplo que se segue [https://scikit-learn.org/stable/auto\\_examples/classification/plot\\_classifier\\_comparison.html](https://scikit-learn.org/stable/auto_examples/classification/plot_classifier_comparison.html), com algumas alterações para *Decision Tree*, *Random Forest*, *MLP Neural Network* e *Linear SVM*.

Na *Decision Tree* e na *Random Forest*, a profundidade máxima da árvore não foi definida, portanto os nós são expandidos até que todas as folhas sejam puras ou até que todas as folhas contenham menos de 2 amostras. Na *MLP Neural Network*, o número máximo de iterações foi definido como 200. No *Linear SVM* o suporte multiclasse é tratado de acordo com um esquema de um contra um.

Considerando os resultados da classificação, os classificadores *Quadratic Discriminant Analysis* e *MLP Neural Network* apresentaram resultados semelhantes em termos de acurácia balanceada com desempenho acima de 88% e todos os classificadores, ao utilizar a interseção de características selecionadas, exibiram desempenho melhor em termos de tempo decorrido. No entanto, equilibrando a acurácia e o tempo decorrido, utilizar uma *MLP Neural Network* com a interseção dos atributos selecionados apresentou o melhor desempenho. Portanto, para exemplificar os resultados finais foi selecionado este classificador e a Figura 33 apresenta sua matriz de confusão.

Figura 33 - Matriz de Confusão para o Classificador *MLP Neural Network* utilizando a interseção dos atributos selecionados



Fonte: Elaborada pelo autor (2022).

## 5 CONCLUSÃO

Os objetivos deste trabalho foram a apresentação um protótipo de baixo custo para aquisição de dados e corrente e tensão das três fases do motor do torno em tempo real. A caracterização das séries temporais da corrente de alimentação das três fases do motor de giro de um torno de forma comparativa com uma simplificação matemática do processo a fim de validar o protótipo de aquisição de dados. E também uma extensão do método TSFRESH e do teste de KS para um cenário multiclasse, aplicado à um problema real de engenharia mecânica para detecção de falhas de ferramentas de corte de torno e classificação da ferramenta em relação ao estágio de sua vida. O ciclo de vida da ferramenta neste trabalho foi dividido entre condição adequada de operação, condição intermediária e condição inadequada de operação.

Foi realizada uma comparação entre os sinais de operação real do motor e aqueles resultantes da simplificação matemática, tendo como objetivo avaliar a eficácia do sistema de aquisição de dados empregado. Observou-se que os resultados fornecidos pelo sistema apresentaram uma alta fidelidade em relação à realidade observada, evidenciando sua capacidade de registrar de forma precisa as variáveis de interesse.

É importante salientar que a precisão na aquisição de dados é fundamental para o desenvolvimento de modelos matemáticos e simulações que permitam a compreensão do comportamento de sistemas complexos, como é o caso do motor estudado. Assim, os resultados obtidos por meio do sistema de aquisição de dados contribuem de forma significativa para a obtenção de informações confiáveis e precisas sobre o desempenho do motor, auxiliando em sua otimização e melhoria contínua.

O modelo proposto pode identificar os padrões que distinguem as operações da ferramenta de corte como adequadas, intermediárias ou em condições inadequadas, alcançando desempenhos satisfatórios em todos os casos. Portanto, o modelo proposto permite evitar a fabricação de peças defeituosas, desperdício de ferramentas e ocorrência de falhas. Utilizando este modelo, em uma estratégia de manutenção baseada em condições, é possível aumentar a confiabilidade, qualidade e disponibilidade do processo de usinagem e reduzir as perdas econômicas.

Além disso, o algoritmo SODA fornece um reconhecimento de similaridade mais preciso entre os dados do que os métodos tradicionais de agrupamento/particionamento, devido ao fato de considerar tanto a divergência espacial quanto a angular. Além disso, demonstra um excelente desempenho quando aplicado a situações de grande escala e de alta dimensão sem parâmetros dependentes do usuário, assim, diminuindo a interferência humana na aplicação do modelo proposto.

Como indicação para trabalhos futuros, é pretendido aplicar a SODA no processamento online de dados em tempo real relacionados à análise de séries temporais do motor

do torno. Adicionalmente, também é pretendido implementar uma abordagem diferenciada na etapa de classificação, como sistemas fuzzy, que resultaria em um estudo detalhado da etapa de seleção de atributos visando gerar um modelo interpretável capaz de lidar com incertezas nos dados medidos. Além disso, apresentar o modelo discutido neste trabalho a outros problemas de engenharia, como por exemplo, máquinas rotativas, evitando a ocorrência de falhas e classificando-as de forma a auxiliar os profissionais não apenas nos processos de tomada de decisão, mas também na elaboração de estratégias na indústria.

## REFERÊNCIAS

- 1 GARDNER BUSINESS MEDIA INC. 2020 world machine tool survey shows machine tool downturn, 2021. <https://www.gardnerweb.com/blog/post/2020-world-machine-tool-survey-shows-machine-tool-downturn>, Accessed: 2022-02-27.
- 2 S. KLINE. Pandemic continues machine tool industry downturn, but u.s. now a top 4 producer, 2021. <https://www.mmsonline.com/articles/pandemic-continues-machine-tool-industry-downturn-but-us-now-a-top-3-producer>, Accessed: 2022-02-27.
- 3 A.K.S. JARDINE, D. LIN, and D. BANJEVIC. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7):1483–1510, 2006. doi: <https://doi.org/10.1016/j.ymsp.2005.09.012>.
- 4 R.K. MOBLEY. *An Introduction to Predictive Maintenance*. Butterworth-Heinemann, Woburn, MA, 2002. doi: <https://doi.org/10.1016/B978-0-7506-7531-4.X5000-3>.
- 5 A. RASTEGARI and M. MOBIN. Maintenance decision making, supported by computerized maintenance management system. In *2016 Annual Reliability and Maintainability Symposium (RAMS)*, pages 1–8, Tucson, AZ, USA, 2016. IEEE. doi: <https://doi.org/10.1109/RAMS.2016.7448086>.
- 6 E.M. TRENT and P.K. WRIGHT. *Metal Cutting*. Butterworth-Heinemann, Amsterdam, 2015.
- 7 R. LIU, A. KOTHURU, and S. ZHANG. Calibration-based tool condition monitoring for repetitive machining operations. *Journal of Manufacturing Systems*, 54:285–293, 2020. doi: <https://doi.org/10.1016/j.jmsy.2020.01.005>.
- 8 F. AGHAZADEH, A. TAHAN, and M. THOMAS. Tool condition monitoring using spectral subtraction and convolutional neural networks in milling process. *The International Journal of Advanced Manufacturing Technology*, 98(9):3217–3227, 2018. doi: <https://doi.org/10.1007/s00170-018-2420-0>.
- 9 D.L. SIMON, S. BORGUET, O. LÉONARD, and X. ZHANG. Aircraft engine gas path diagnostic methods: public benchmarking results. *Journal of Engineering for Gas Turbines and Power*, 136(4), 2013. doi: <https://doi.org/10.1115/1.4025482>.
- 10 G.E.P. BOX, G.M. JENKINS, G.C. REINSEL, and G.M. LJUNG. *Time series analysis: forecasting and control*. John Wiley Sons, 2015.
- 11 R.H. SHUMWAYhumway and D.S. STOFFER. *Time series analysis and its applications*. Springer, 4th edition, 2017. doi: <https://doi.org/10.1007/978-3-319-52452-8>.
- 12 W.W.S. WEI. Time series analysis. *The Oxford Handbook of Quantitative Methods in Psychology*, 2, 2013. doi: <https://doi.org/10.1093/oxfordhb/9780199934898.013.0022>.
- 13 M. CHRIST, N. BRAUN, J. NEUFFER, and A. W. KEMPA-LIEHR. Time series feature extraction on basis of scalable hypothesis tests (tsfresh – a python package). *Neurocomputing*, 307:72–77, 2018. doi: <https://doi.org/10.1016/j.neucom.2018.03.067>.

- 14 R. WILCOX. Kolmogorov–smirnov test. *Encyclopedia of biostatistics*, 2005. doi: <https://doi.org/10.1002/0470011815.b2a15064>.
- 15 I.T. JOLLIFFE. *Principal Component Analysis and Factor Analysis*. Springer New York, New York, NY, 1986. doi: [https://doi.org/10.1007/978-1-4757-1904-8\\_7](https://doi.org/10.1007/978-1-4757-1904-8_7).
- 16 X. GU, P. ANGELOV, D. KANGIN, and J.C. PRINCIPE. Self-organised direction aware data partitioning algorithm. *Information Sciences*, 423:80–95, 2018. doi: <https://doi.org/10.1016/j.ins.2017.09.025>.
- 17 P. ANGELOV. Outside the box: an alternative data analytics framework. *Journal of Automation, Mobile Robotics and Intelligent Systems*, 8(2):29–35, 2014. doi: [https://doi.org/10.14313/JAMRIS\\_2-2014/16](https://doi.org/10.14313/JAMRIS_2-2014/16).
- 18 P. ANGELOV, X. GU, and D. KANGIN. Empirical data analytics. *International Journal of Intelligent Systems*, 32(12):1261–1284, 2017. doi: <https://doi.org/10.1109/SMC.2016.7844219>.
- 19 P. ANGELOV, X. GU, and J.C. PRÍNCIPE. A generalized methodology for data analysis. *IEEE transactions on cybernetics*, 48(10):2981–2993, 2018. doi: <https://doi.org/10.1109/TCYB.2017.2753880>.
- 20 C.M. BISHOP. *Pattern recognition and machine learning*. Springer New York, New York, NY, 2016.
- 21 E. D. DIMLA. Sensor signals for tool-wear monitoring in metal cutting operations – a review of methods. *International Journal of Machine Tools Manufacture*, 40(8):1073–1098, 2000. doi: [https://doi.org/10.1016/S0890-6955\(99\)00122-4](https://doi.org/10.1016/S0890-6955(99)00122-4).
- 22 J.L. STEIN, D. COLVIN, G. CLEVER, and C.H. WANG. Evaluation of dc servo machine tool feed drives as force sensors. *Journal of Dynamic Systems, Measurement, and Control*, 108(4):279–288, 1986. doi: <https://doi.org/10.1115/1.3143795>.
- 23 Y. ALTINTAS and J. PENG. Design and analysis of a modular cnc system. *Computers in Industry*, 13(4):305–316, 1990. doi: [https://doi.org/10.1016/0166-3615\(90\)90003-8](https://doi.org/10.1016/0166-3615(90)90003-8).
- 24 Y. ALTINTAS. Prediction of cutting forces and tool breakage in milling from feed drive current measurements. *Journal of Engineering for Industry*, 114(4):386–392, 1992. doi: <https://doi.org/10.1115/1.2900688>.
- 25 Y.C. CHANG, K.T. LEE, and H.Y. CHUANG. Cutting force estimation of spindle motor. *Journal of Control Systems and Technology*, 3(2):145–152, 1995.
- 26 J. M. LEE, D. K. CHOI, J. KIM, and C.N. CHU. Real-time tool breakage monitoring for nc milling process. *CIRP annals*, 44(1):59–62, 1995. doi: [https://doi.org/10.1016/S0007-8506\(07\)62275-6](https://doi.org/10.1016/S0007-8506(07)62275-6).
- 27 T.Y. KIM and J. KIM. Adaptive cutting force control for a machining center by using indirect cutting force measurements. *International Journal of Machine Tools and Manufacture*, 36(8):925–937, 1996. doi: [https://doi.org/10.1016/0890-6955\(96\)00097-1](https://doi.org/10.1016/0890-6955(96)00097-1).

- 28 H. OKTEM, T. ERZURUMLU, and F. ERZINCANLI. Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm. *Materials & design*, 27(9):735–744, 2006. doi: <https://doi.org/10.1016/j.matdes.2005.01.010>.
- 29 T. ÖZEL, Y. KARPAT, L. FIGUEIRA, and J.P. DAVIM. Modelling of surface finish and tool flank wear in turning of aisi d2 steel with ceramic wiper inserts. *Journal of materials processing technology*, 189(1-3):192–198, 2007. doi: <https://doi.org/10.1016/j.jmatprotec.2007.01.021>.
- 30 J. YUAN, K. WANG, T. YU, and M. FANG. Reliable multi-objective optimization of high-speed wedm process based on gaussian process regression. *International Journal of Machine Tools and Manufacture*, 48(1):47–60, 2008. doi: <https://doi.org/10.1016/j.ijmachtools.2007.07.011>.
- 31 S. ASSARZADEH and M. GHOREISHI. Neural-network-based modeling and optimization of the electro-discharge machining process. *The International Journal of Advanced Manufacturing Technology*, 39(5-6):488–500, 2008. doi: <https://doi.org/10.1007/s00170-007-1235-1>.
- 32 M. I. HOSSAIN, A.K.M.N. AMIN, and A.U. PATWARI. Development of an artificial neural network algorithm for predicting the surface roughness in end milling of inconel 718 alloy. In *2008 International Conference on Computer and Communication Engineering*, pages 1321–1324, Kuala Lumpur, Malaysia, 2008. IEEE. doi: <https://doi.org/10.1109/ICCCE.2008.4580819>.
- 33 U. ÇAYDAŞ and A. HASÇALIK. A study on surface roughness in abrasive waterjet machining process using artificial neural networks and regression analysis method. *Journal of materials processing technology*, 202(1-3):574–582, 2008. doi: <https://doi.org/10.1016/j.jmatprotec.2007.10.024>.
- 34 S.S. PANDA and S.S. MAHAPATRA. Pca fused nn approach for drill wear prediction in drilling mild steel specimen. In *2009 2nd IEEE International Conference on Computer Science and Information Technology*, pages 85–89, Beijing, China, 2009. IEEE. doi: <http://doi.org/10.1109/ICCSIT.2009.5234475>.
- 35 L. K. YOUNG, D.N. MAVRIS, V.V. VOLOVOI, M. YUAN, and T. FISHER. A fault diagnosis method for industrial gas turbines using bayesian data analysis. *Journal of Engineering for Gas Turbines and Power*, 132(4), 2010. doi: <https://doi.org/10.1115/1.3204508>.
- 36 F.J. PONTES, A.P. DE PAIVA, P.P. BALESTRASSI, J.R. FERREIRA, and M.B. DA SILVA. Optimization of radial basis function neural network employed for prediction of surface roughness in hard turning process using taguchi’s orthogonal arrays. *Expert Systems with Applications*, 39(9):7776–7787, 2012. doi: <https://doi.org/10.1016/j.eswa.2012.01.058>.
- 37 P.B. HUANG, C.C. MA, and C.H. KUO. A pnn self-learning tool breakage detection system in end milling operations. *Applied Soft Computing*, 37(1):114–124, 2015. doi: <https://doi.org/10.1016/j.asoc.2015.08.019>.

- 38 Y.M. ARISOY and T. ÖZEL. Machine learning based predictive modeling of machining induced microhardness and grain size in ti-6al-4v alloy. *Materials and Manufacturing Processes*, 30(4):425–433, 2015. doi: <https://doi.org/10.1080/10426914.2014.961476>.
- 39 T. BENKEDJOUH, K. MEDJAHHER, N. ZERHOUNI, and S. RECHAK. Health assessment and life prediction of cutting tools based on support vector regression. *Journal of Intelligent Manufacturing*, 26(2):213–223, 2015. doi: <https://doi.org/10.1007/s10845-013-0774-6>.
- 40 D.Y. JANG, J. JUNG, and J. SEOK. Modeling and parameter optimization for cutting energy reduction in mql milling process. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 3(1):5–12, 2016. doi: <https://doi.org/10.1007/s40684-016-0001-y>.
- 41 D. WU, C. JENNINGS, J. TERPENNY, R.X. GAO, and S. KUMARA. A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests. *Journal of Manufacturing Science and Engineering*, 139(7), 2017. doi: <https://doi.org/10.1115/1.4036350>.
- 42 A. CAGGIANO. Tool wear prediction in ti-6al-4v machining through multiple sensor monitoring and pca features pattern recognition. *Sensors*, 18(3), 2018. doi: <https://doi.org/10.3390/s18030823>.
- 43 A. CAGGIANO, R. ANGELONE, F. NAPOLITANO, L. NELE, and R. TETI. Dimensionality reduction of sensorial features by principal component analysis for ann machine learning in tool condition monitoring of cfrp drilling. *Procedia CIRP*, 78: 307–312, 2018. ISSN 2212-8271. doi: <https://doi.org/10.1016/j.procir.2018.09.072>. 6th CIRP Global Web Conference – Envisaging the future manufacturing, design, technologies and systems in innovation era (CIRPe 2018).
- 44 K. DONGDONG, C. YONGJIE, and L. NING. Gaussian process regression for tool wear prediction. *Mechanical Systems and Signal Processing*, 104:556–574, 2018. doi: <https://doi.org/10.1016/j.ymsp.2017.11.021>.
- 45 P. KRISHNAKUMAR, K. RAMESHKUMAR, and K.I. RAMACHANDRAN. Acoustic emission-based tool condition classification in a precision high-speed machining of titanium alloy: A machine learning approach. *International Journal of Computational Intelligence and Applications*, 17(3), 2018. doi: <https://doi.org/10.1142/S1469026818500177>.
- 46 Y. CHEN, Y. JIN, and G. JIRI. Predicting tool wear with multi-sensor data using deep belief networks. *The International Journal of Advanced Manufacturing Technology*, 99(5):1917–1926, 2018. doi: <https://doi.org/10.1007/s00170-018-2571-z>.
- 47 A. GOUARIR, G. MARTÍNEZ-ARELLANO, G. TERRAZAS, P. BENARDOS, and S. RATCHEV. In-process tool wear prediction system based on machine learning techniques and force analysis. *Procedia CIRP*, 77:501–504, 2018. doi: <https://doi.org/10.1016/j.procir.2018.08.253>. 8th CIRP Conference on High Performance Cutting (HPC 2018).

- 48 W. LI and T. LIU. Time varying and condition adaptive hidden markov model for tool wear state estimation and remaining useful life prediction in micro-milling. *Mechanical Systems and Signal Processing*, 131:689–702, 2019. ISSN 0888-3270. doi: <https://doi.org/10.1016/j.ymssp.2019.06.021>.
- 49 X. LI, W. ZHANG, Q. DING, and J.Q. SUN. Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation. *Journal of Intelligent Manufacturing*, 31(2):433–452, 2020. doi: <https://doi.org/10.1007/s10845-018-1456-1>.
- 50 B. NIU, J. SUN, and B. YANG. Multisensory based tool wear monitoring for practical applications in milling of titanium alloy. *Materials Today: Proceedings*, 22:1209–1217, 2020. ISSN 2214-7853. doi: <https://doi.org/10.1016/j.matpr.2019.12.126>. International Conference on Materials Engineering and Characterization 2019.
- 51 C. ZHOU, B. YANG, K. GUO, J. LIU, J. SUN, G. SONG, S. ZHU, C. SUN, and Z. JIANG. Vibration singularity analysis for milling tool condition monitoring. *International Journal of Mechanical Sciences*, 166:105254, 2020. doi: <https://doi.org/10.1016/j.ijmecsci.2019.105254>.
- 52 J. OU, H. LI, G. HUANG, and Q. ZHOU. A novel order analysis and stacked sparse auto-encoder feature learning method for milling tool wear condition monitoring. *Sensors*, 20(10), 2020. doi: <https://doi.org/10.3390/s20102878>.
- 53 H. SUN, J. ZHANG, R. MO, and X. ZHANG. In-process tool condition forecasting based on a deep learning method. *Robotics and Computer-Integrated Manufacturing*, 64:101924, 2020. doi: <https://doi.org/10.1016/j.rcim.2019.101924>.
- 54 H. JAIN, P. KUMAR, S. KUMAR, and P. KUMAR. Fault detection and diagnosis in cnc turning machines using motor current signature analysis. *Journal of Manufacturing Processes*, 32:655–665, 2018. doi: <https://doi.org/10.1016/j.jmapro.2018.03.020>.
- 55 Y. ERSAN and E. BUDAK. Cutting tool wear classification by using motor current signals in turning operations. *International Journal of Machine Tools and Manufacture*, 57:83–88, 2012. doi: <https://doi.org/10.1016/j.ijmachtools.2012.01.002>.
- 56 S. ISLAM, M.R. SARKER, and A. BASAK. Application of current signature analysis for tool wear monitoring in turning operations. *Journal of Manufacturing Science and Engineering*, 133:031006, 2011. doi: <https://doi.org/10.1115/1.4004504>.
- 57 T.E. FERNANDES, M.A.M. FERREIRA, G.P.C. MIRANDA, A.F. DUTRA, M.P. ANTUNES, M.V.G.R. SILVA, and E.P. AGUIAR. Multivariate time series and machine learning techniques for the multi-class classification of lathe’s cutting tools wear condition. *XXIV Congresso Brasileiro de Automática*, 2022.
- 58 M.A.M. FERREIRA, T.E. FERNANDES, G.P.C. MIRANDA, A.F. DUTRA, M.P. ANTUNES, M.V.G.R. SILVA, and E.P. AGUIAR. Análise de relevância de atributos para classificação de falhas de ferramentas de corte utilizando tsfresh. *LX Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, 2022. doi: <http://dx.doi.org/10.14209/sbrt.2022.1570823732>.

- 59 T.E. FERNANDES, M.A.M. FERREIRA, G.P.C. MIRANDA, A.F. DUTRA, M.P. ANTUNES, M.V.G.R. SILVA, and E.P. AGUIAR. Classification of lathe's cutting tool wear based on an autonomous machine learning model. *Journal of Control, Automation and Electrical Systems*, 33:167–182, 2022. doi: <https://doi.org/10.1007/s40313-021-00819-5>.
- 60 T.E. FERNANDES, G.P.C. MIRANDA, A.F. DUTRA, M.A.M. FERREIRA, M.P. ANTUNES, M.V.G.R. SILVA, and E.P. AGUIAR. An autonomous model to classify lathe's cutting tools based on tsfresh, self-organised direction aware data partitioning algorithm and machine learning techniques.
- 61 H. SHAO, H.L. WANG, and X.M. ZHAO. A cutting power model for tool wear monitoring in milling. *International Journal of Machine Tools and Manufacture*, 44(14):1503–1509, 2004. doi: <https://doi.org/10.1016/j.ijmachtools.2004.05.003>.
- 62 X. LI, A. DJORDJEVICH, and P.K. VENUVINOD. Current-sensor-based feed cutting force intelligent estimation and tool wear condition monitoring. *IEEE Transactions on Industrial Electronics*, 47(3):697–702, 2000. doi: <https://doi.org/10.1109/41.847910>.
- 63 M. CHRIST, N. BRAUN, J. NEUFFER, and A. W. KEMPA-LIEHR. Tsfresh - introduction. 2021. URL <https://tsfresh.readthedocs.io/en/latest/text/introduction.html>. Acesso em: 2022-11-13.
- 64 P. RADIVOJAC, Z. OBRADOVIC, A.K. DUNKER, and S. VUCETIC. Feature selection filters based on the permutation test. In *European Conference on Machine Learning*, volume 3201, pages 334–346, Berlin, DE, 2004. Springer-Verlag. doi: [https://doi.org/10.1007/978-3-540-30115-8\\_32](https://doi.org/10.1007/978-3-540-30115-8_32).
- 65 M. CHRIST, A. W. KEMPA-LIEHR, and M. FEINDT. Distributed and parallel time series feature extraction for industrial big data applications. *CoRR*, abs/1610.07717, 2016. URL <http://arxiv.org/abs/1610.07717>.
- 66 A. OKABE, B. BOOTS, K. SUGIHARA, and S.N. CHIU. *Spatial tessellations: concepts and applications of Voronoi diagrams*. John Wiley Sons, Chichester, Sussex, 2000.
- 67 R. KOHAVI. A study of cross-validation and bootstrap for accuracy estimation and model selection. page 1137–1143, 1995.
- 68 F. PEDREGOSA, G. VAROQUAUX, A. GRAMFORT, V. MICHEL, B. THIRION, O. GRISEL, M. BLONDEL, P. PRETTENHOFER, R. WEISS, V. DUBOURG, J., VANDERPLAS, A. PASSOS, D. COURNAPEAU, M. BRUCHER, M. PERROT, and E. DUCHESNAY. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12(85):2825–2830, 2011. URL <http://jmlr.org/papers/v12/pedregosa11a.html>.