

**UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC  
CENTRO DE CIÊNCIAS TECNOLÓGICAS — CCT  
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA – PPGEM**

**KAROLINE CONCEIÇÃO DA FONSECA SANTOS**

**MONITORAMENTO DA VARIAÇÃO DE DUREZA DO AÇO AISI 4340  
EMPREGANDO MÁQUINA DE VETOR DE SUPORTE EM OPERAÇÃO DE  
USINAGEM.**

**JOINVILLE**

**2022**

**KAROLINE CONCEIÇÃO DA FONSECA SANTOS**

**MONITORAMENTO DA VARIAÇÃO DE DUREZA DO AÇO AISI 4340  
EMPREGANDO MÁQUINA DE VETOR DE SUPORTE EM OPERAÇÃO DE  
USINAGEM.**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr-Ing. Joel Martins Crichigno Filho

**JOINVILLE**

**2022**

Ficha catalográfica elaborada pelo programa de geração automática da Biblioteca Setorial do CCT/UEDESC, com os dados fornecidos pelo(a) autor(a)

SANTOS , KAROLINE CONCEIÇÃO DA FONSECA

Monitoramento da variação de dureza do aço AISI 4340 empregando Máquina de Vetor de Suporte em operação de usinagem. / KAROLINE CONCEIÇÃO DA FONSECA SANTOS . - Joinville, 2022.

75 p. : il. ; 30 cm.

Orientador: Prof. Dr-Ing. Joel Martins Crichigno Filho.

Dissertação (Mestrado) - Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa De Pós-Graduação Em Engenharia Mecânica, Joinville, 2022.

1. Palavra-chave.Monitoramento. 2. Palavra-chave. Indústria 4.0 3. Palavra-chave.Fresamento 4. Palavra-chave. Usinagem 5. Palavra-chave. SVM I. Crichigno Filho, Prof. Dr-Ing. Joel Martins . II. Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa De Pós-Graduação Em Engenharia Mecânica.

**KAROLINE CONCEIÇÃO DA FONSECA SANTOS**

**MONITORAMENTO DA VARIAÇÃO DE DUREZA DO AÇO AISI 4340  
EMPREGANDO MÁQUINA DE VETOR DE SUPORTE EM OPERAÇÃO DE  
USINAGEM.**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr-Ing. Joel Martins Crichigno Filho

**BANCA EXAMINADORA:**

Joel Martins Crichigno Filho, Dr.-Ing;  
Universidade do Estado de Santa Catarina (UDESC/Joinville)

Membros:

Adriano Fagali de Souza, Dr.Eng.  
Universidade Federal de Santa Catarina (UFSC/Joinville)

Fernando Humel Lafratta, Dr.Eng.  
Universidade do Estado de Santa Catarina (UDESC/Joinville)

Joinville, 27 de julho de 2022

Dedico este trabalho à Hilma Conceição que  
sempre me apoiou nesta jornada de estudos!

## **AGRADECIMENTOS**

Agradeço ao meu orientador, Prof. Dr. Joel Martins Crichigno Filho, pelos momentos de orientação durante o desenvolvimento do trabalho.

À minha irmã Dra. Hilma Conceição da Fonseca Santos, que sempre me incentiva a conquistar os meus objetivos.

A Caique dos Santos Conceição, pela paciência e incentivo.

Ao Técnico de Laboratório da Universidade do Estado de Santa Catarina (UDESC), Charles Costa, que me acompanhou durante os ensaios.

Aos professores do departamento de pós-graduação em Engenharia Mecânica da UDESC, que me auxiliaram neste período de estudos.

Ao Willian Kévin Rauber, por sempre me escutar e incentivar nos momentos de estresse e em que o desânimo batia.

A FAPESC (Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina) que suporta o laboratório através do projeto 2021TR843.

Ao órgão CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela bolsa de estudo e a Universidade do Estado de Santa Catarina (UDESC) pela estrutura.

“Minha luta diária é para ser reconhecida como  
sujeito, impor minha existência numa sociedade  
que insiste em negá-la.” (Djamila Ribeiro)

## RESUMO

O monitoramento na usinagem tem como principal propósito detectar variações durante o processo, antes que peças defeituosas sejam produzidas. Esta pode servir, ainda, como base para otimizar e automatizar o processo, acelerando a tomada de decisão. Esse cenário é uma das bases da Indústria 4.0 no que se refere aos processos de usinagem. Nos anos recentes, a Internet das coisas (Iot) representa o principal núcleo da indústria 4.0, para alavancar o ambiente industrial. Além disso, a variação da dureza do material em lotes de peças pode levar não somente ao desgaste prematuro da ferramenta, mas também influenciar na propriedade do material. Deste modo, essa dissertação tem o propósito desenvolver o sistema inteligente para detectar a variação de dureza de material das peças durante a usinagem no processo de fresamento. O material empregado foi aço SAE 4340 utilizado quatro tarugos (corpo de prova) com as mesmas dimensões, porém cada corpo de prova tinha um tipo de dureza superficial, tais como: 32HRC, 36HRC, 42HRC e 45HRC. Para o desenvolvimento do sistema utilizou microcontroladores de baixo custo para adquirir os sinais dos sensores, tratar e enviar por conexão sem fio ao computador. Para monitorar os sinais de corrente do motor do eixo-arvore foi empregada a placa ESP8266 com o sensor de efeito hall SCT-013-100 e uma placa Raspberry Pi Zero conectada ao microfone omnidirecional Inmp44 para aquisição dos sinais de pressão sonora que foram gerados durante o processo de fresamento. Os sinais adquiridos pelas placas foram enviados para um PC via rede wifi. Posteriormente, os dados foram analisados a fim de verificar se existe variação da dureza através do sinal adquirido e com isso foi empregado a técnica de máquina de vetor de suporte (SVM) para auxiliar na classificação do aço por nível de dureza. Ao analisar os dados constatou que os parâmetros monitorados foram sensíveis à variação de dureza da peça e aplicação do SVM foi útil para categorizar o aço por nível de dureza. Além disso, a escolha da função Kernel e a quantidade de atributos influenciou nos resultados. Entre a função kernel RBF, polinomial e sigmoide a que teve maior confiabilidade nos resultados foi a função kernel RBF com 5 atributos.

**Palavras-chave:** Monitoramento. Indústria 4.0. Fresamento. Usinagem. SVM.

## ABSTRACT

The main purpose of the machining process monitoring is to detect variations before defective workpieces are produced. This can serve as a basis for optimizing and automating the machining process. This scenario is one of the foundations of Industry 4.0 in terms of manufacturing processes. In recent years, the Internet of Things (IoT) emerges within the Industry 4.0, to stimulate the industrial environment. Since the material hardness variation in batches of parts can lead to premature wear of the tool and also influence the property of the material; the objective of the work is to develop an intelligent system to detect the material hardness variation of workpieces during the milling process. The material used was SAE 4340 steel used four billets (specimen) with the same dimensions, but each specimen had a type of surface hardness, such as: 32HRC, 36HRC, 42HRC and 45HRC. For the development of the system, we used low-cost microcontrollers to acquire the sensor signals, process and send wirelessly to the computer. To monitoring the signals of the current of the spindle motor, the ESP8266 board was used with the hall effect sensor SCT-013-100 and a Raspberry Pi Zero board connected to the Inmp44 omnidirectional microphone for the acquisition of the sound pressure signals that were generated during the sealing process. The signals acquired by the cards were sent to a PC via wifi network. Subsequently, the data were analyzed in order to verify some variation in hardness through the acquired signal. Additionally, the support vector machine (SVM) technique was used to assist in the Steel classification by hardness level. As a result, it was possible to notice that the parameters monitored were sensitive to the hardness variation of the part and application of SVM. It was useful to categorize steel by hardness level. In addition, the choice of Kernel function and the amount of attributes influenced the results. Among the RBF kernel function, polynomial and sigmoid to which had greater reliability in the results was the RBF kernel function with 5 attributes.

**Keywords:** Monitoring. Industry 4.0. Milling. Machining. SVM.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Resumo das revoluções industriais. . . . .	19
Figura 2 – Tecnologias presentes na Indústria 4.0. . . . .	20
Figura 3 – Parâmetro de corte . . . . .	22
Figura 4 – Sentido de corte. . . . .	23
Figura 5 – Metodologia para desenvolver sistema de monitoramento para processos de usinagem. . . . .	25
Figura 6 – Exemplo de geração de ruído, transmissão e irradiação em um centro de usinagem. . . . .	29
Figura 7 – Exemplo do processo de produção de um sinal de vibração simplificado. . .	30
Figura 8 – Fontes de emissão acústica em vários estágios de remoção de material. . . .	31
Figura 9 – Estrutura básica de um microcontrolador. . . . .	32
Figura 10 – Placa Raspberry Pi. . . . .	33
Figura 11 – Placa ESP 8266. . . . .	33
Figura 12 – Arduino Uno. . . . .	34
Figura 13 – Processamento do sinal. . . . .	35
Figura 14 – Quantificação do sinal harmônico. . . . .	37
Figura 15 – Variação dos valores de Fator de Crista em função da variação dos valores de pico e RMS . . . . .	37
Figura 16 – Aplicação de SVM. . . . .	40
Figura 17 – Linearmente separável. . . . .	41
Figura 18 – Hiperplano de separação. . . . .	41
Figura 19 – Cálculo da distância $d$ entre os hiperplanos $H_1$ e $H_2$ . . . . .	43
Figura 20 – Comprimento do vetor projetado. . . . .	43
Figura 21 – SVM com marges flexíveis. . . . .	45
Figura 22 – Metodologia proposta. . . . .	48
Figura 23 – Arranjo da instalação para aquisição do sinal da corrente. . . . .	50
Figura 24 – Aquisição do sinal da corrente. . . . .	51
Figura 25 – Arranjo da instalação para aquisição do sinal da pressão sonora. . . . .	51
Figura 26 – Aquisição dos sinais de pressão sonora. . . . .	52
Figura 27 – Aquisição dos sinais para treinamento SVM . . . . .	52
Figura 28 – Matriz de Confusão para classificação multiclasse. . . . .	54
Figura 29 – Sinal da corrente em função do tempo (A-entrada da ferramenta, B- regime de corte, C- saída da ferramenta da peça, D- desligamento do motor. . . . .	55
Figura 30 – Sinal de corrente RMS do primeiro ponto para diferentes durezas do material da peça A-32HRC, B-36HRC, C-42HRC e D-45HRC. . . . .	56
Figura 31 – Sinal da pressão sonora no domínio do tempo para a dureza 17 HRC. . . . .	57
Figura 32 – RMS do sinal sonoro. . . . .	58

Figura 33 – Valor de pico do sinal sonoro. . . . .	58
Figura 34 – Fator de Crista do sinal sonoro. . . . .	59
Figura 35 – Curtose. . . . .	59
Figura 36 – Precisão aplicando a função kernel RBF. . . . .	65
Figura 37 – Acurácia aplicando a função kernel RBF . . . . .	65
Figura 38 – Tempo de treinamento para função kernel RBF. . . . .	66
Figura 39 – Aplicação do RBF para cinco atributos. . . . .	67

## LISTA DE TABELAS

Tabela 1 – Exemplos de métodos de medição. . . . .	26
Tabela 2 – Comparação entre as placas Arduino, Raspberry Pi Zero e ESP8266. . . . .	34
Tabela 3 – Funções Kernel mais comum. . . . .	46
Tabela 4 – Composição química do aço AISI 4340 por porcentagem em peso. . . . .	49
Tabela 5 – Propriedades mecânicas típicas de um aço AISI/SAE 4340. . . . .	49
Tabela 6 – classificação por nível de dureza . . . . .	53
Tabela 7 – Modelo da matriz de confusão do número de amostra, precisão e da acurácia. . . . .	54
Tabela 8 – Correlação dos parâmetros estatísticos com o nível de dureza e sua significância para análise. . . . .	60
Tabela 9 – Matriz de confusão do modelo com cinco atributos aplicando a função kernel RBF. . . . .	61
Tabela 10 – Matriz de confusão do modelo com cinco atributos aplicando a função kernel sigmoid. . . . .	61
Tabela 11 – Matriz de confusão com os cinco parâmetros estatísticos no domínio do tempo aplicando a função kernel polinomial. . . . .	62
Tabela 12 – Matriz de confusão com quatro atributos aplicando a função kernel RBF. . . . .	63
Tabela 13 – Matriz de confusão para o modelo com três atributos aplicando a função kernel RBF. . . . .	63
Tabela 14 – Matriz de confusão para o modelo com dois atributos aplicando a função kernel RBF. . . . .	64
Tabela 15 – Matriz de confusão da validação para o modelo com dois atributos aplicando a função kernel RBF. . . . .	66

## **LISTA DE ABREVIATURAS E SIGLAS**

IOT	Internet of Things
SVM	Support Vector Machine
IA	Inteligência artificial
RNA	Rede neural artificial
RMS	Root Mean Square
KNN	Nearest Neighbors
RF	Random Forest
RBF	Função base radial
Udesc	Universidade do Estado de Santa Catarina

## LISTA DE SÍMBOLOS

$a_e$	Penetração de trabalho/ profundidade radial [mm]
$a_p$	Profundidade de corte/ profundidade axial [mm]
D	Diâmetro da fresa [mm]
dB	Decibel
$f_z$	Avanço por dente
$v_c$	velocidade de corte [m/min]
$P_c$	Potência de corte [kW]
$F_c$	Força de corte [N]
$P_m$	Potência consumida pelo motor [kW]
$\eta$	Rendimento da máquina
$k_c$	Pressão específica de corte [ $N/mm^2$ ]
v	Tensão [V]
z	Número de dentes da ferramenta
$\theta$	Ângulo de fase
I	Corrente
k	Função kernel
C	Parâmetro de regularização
w	Vetor diretor do hiperplano classificador
x	Vetor características do dado de treinamento
b	Bias
$\alpha_i$	Variável Lagrangeana
$\xi_i$	Variável de folga do problema de otimização
$\gamma$	Hiperparâmetro do kernel gaussiano
$\alpha^*$	Variável de decisão ótima

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	OBJETIVO GERAL	17
1.2	OBJETIVO ESPECÍFICO	17
1.3	ESTRUTURA DA DISSERTAÇÃO	17
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>19</b>
2.1	TECNOLOGIAS PRESENTE NA INDÚSTRIA 4.0	19
2.2	FRESAMENTO	21
<b>2.2.1</b>	<b>Parâmetros de corte no fresamento</b>	<b>22</b>
2.2.1.1	<i>Sentido de corte</i>	23
<b>2.2.2</b>	<b>Ferramenta de corte</b>	<b>23</b>
2.3	MONITORAMENTO NA USINAGEM	24
<b>2.3.1</b>	<b>Monitoramento através da corrente do motor eixo-árvore</b>	<b>27</b>
<b>2.3.2</b>	<b>Monitoramento através da pressão sonora</b>	<b>28</b>
2.4	AQUISIÇÃO DE SINAL	32
<b>2.4.1</b>	<b>Microcontroladores</b>	<b>32</b>
<b>2.4.2</b>	<b>Processamento do sinal</b>	<b>34</b>
2.5	SISTEMAS INTELIGENTES	38
<b>2.5.1</b>	<b>Máquina de vetor de suporte</b>	<b>40</b>
<b>2.5.2</b>	<b>SVM lineares com margens rígidas</b>	<b>41</b>
<b>2.5.3</b>	<b>SVM com margens suaves</b>	<b>44</b>
<b>2.5.4</b>	<b>SVM não lineares</b>	<b>45</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>48</b>
3.1	PLANEJAMENTO DOS EXPERIMENTOS	48
3.2	CARACTERÍSTICAS DO COPO DE PROVA	49
3.3	APARATO EXPERIMENTAL	49
3.4	SISTEMA DE AQUISIÇÃO DE SINAIS	50
3.5	PROCEDIMENTO APLICADO PARA ANÁLISE DOS DADOS	52
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>55</b>
4.1	CORRENTE DO MOTOR DO EIXO-ÁRVORE	55
4.2	PRESSÃO SONORA	56
4.3	APLICAÇÃO DA SVM	60
<b>4.3.1</b>	<b>Influência do Kernel</b>	<b>60</b>
4.3.1.1	<i>Kernel RBF</i>	60
4.3.1.2	<i>Kernel Sigmoid</i>	61
4.3.1.3	<i>Kernel Polinomial</i>	62

<b>4.3.2</b>	<b>Influência dos Parâmetros Extraídos . . . . .</b>	<b>62</b>
<b>4.3.3</b>	<b>Comparação da influência dos parâmetros extraídos . . . . .</b>	<b>64</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>68</b>
<b>5.1</b>	<b>SUGESTÕES PARA TRABALHOS FUTUROS . . . . .</b>	<b>68</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>70</b>

## 1 INTRODUÇÃO

A proposta do trabalho é desenvolver um sistema de monitoramento da dureza do material de peças no fresamento aplicando máquina de vetor de suporte, medindo os sinais da corrente do motor do eixo-árvore e sonoros. Para auxiliar na demanda da indústria, por causa, da variação de dureza do material dos lingotes ou tarugo devido ao processo de fundição, pois anomalias podem ser detectadas durante a fabricação e pode influenciar no custo e tempo de produção. Desta forma, a indústria está em busca de tecnologia simples e de baixo custo não somente para monitorar a dureza do material das peças, mas também, desgaste da ferramenta, rugosidade do material, variação da temperatura, vibração. O monitoramento do processo de fabricação é crucial para acelerar a produtividade e garantir a eficiência do processo.

O sistema de monitoramento inteligente está auxiliando na detecção do sinal e no diagnóstico para tomada de decisão. Portanto, a tecnologia presente na indústria 4.0 está fortemente atrelada ao monitoramento inteligente. A Internet das coisas (Iot) representa o principal núcleo da indústria 4.0, para alavancar o ambiente industrial (ABELLAN-NEBOT; SUBIRÓN, 2010). IOT atrelada microcontroladores e a sensores está cada vez mais auxiliando no diagnóstico do sistema devido às máquinas e equipamentos conectados a sensores que fazem comunicação e interligação entre si ou via rede (LIMA, 2021), (KOTHURU; NOOKA; LIU, 2018), (ABELLAN-NEBOT; SUBIRÓN, 2010); (TAHIR et al., 2016).

Existem diversas técnicas para o monitoramento do processo tais como: monitoramento através da corrente elétrica do motor, da pressão sonora, vibração e da temperatura, por exemplo, ao utilizar um sensor de efeito Hall para medir a corrente elétrica do motor do eixo-árvore da fresadora de modo a verificar a variação da força de corte é possível estimar o desgaste da ferramenta, a dureza do material da peça (RITOU et al., 2014), (TAHIR et al., 2016), (KONG et al., 2017) (KOTHURU; NOOKA; LIU, 2018).

A grande quantidade de dados gerada durante a aquisição de sinais acaba influenciando na tomada de decisão para reagir às variações em menor tempo. A indústria tem bastante interesse na inteligência artificial, pois aumenta o nível na automatização, melhora a análise dos sinais e correlacionando com o estado do processo (ABELLAN-NEBOT; SUBIRÓN, 2010), (PIMENOV et al., 2022). Por exemplo, ao adquirir os sinais da variação da pressão sonora durante o fresamento e esses dados, podem ser utilizados para alimentar um algoritmo e com isso prever a variação da dureza do material, a partir de um conjunto de dados ter informações futuras.

Portanto, a inteligência artificial dando ênfase no aprendizado de máquina, faz com que o processo de usinagem possa ser monitorada de forma eficaz com a previsão e/ou classificação. Por exemplo, na previsão da rugosidade do material, da dureza do material e do desgaste da ferramenta são alguns exemplos que podem ser aplicados no chão de fábrica. Além disso, a seleção correta do método de aprendizado de máquina é de suma importância, pois o *datasets* e o algoritmo aplicado pode influenciar na confiabilidade dos resultados (PIMENOV et al., 2022).

Entre as técnicas de aprendizado de máquina supervisionado máquina de vetor de suporte (SVM) vem ganhando destaque, pois busca maximizar a capacidade de generalização dos dados e minimizar os erros e tem a capacidade de lidar com dados linearmente separáveis e não separáveis. SVM é um algoritmo que busca um hiperplano que separe os dados entre classes distintas tendo como foco reconhecimento de padrões (SANTOS, 2019), (LORENA; CARVALHO, 2007).

Desse modo, a pesquisa está relacionada com o desenvolvimento de um modelo de classificação da dureza do material. Além disso, o aço utilizado foi SAE 4340 com dureza variando de 32 HRC, 36 HRC, 42 HRC e 45 HRC com geometria de peça simples.

Foi aplicado microcontroladores para aquisição do sinal da corrente (RMS) e o sinal sonoro foi adquirido no domínio do tempo e posteriormente realizou uma análise dos parâmetros estatísticos no domínio do tempo. Dessa forma, pretende-se empregar um sistema de sensoria-mento, em seguida um pré-processamento e por fim uma tomada de decisão utilizando técnica de inteligência artificial para classificar o material por nível de dureza.

Ao empregar essa tecnologia, monitoramento de dureza do material *online*, pode facilitar na tomada de decisão e no custos da produção, pois com os sinais adquiridos, pode ter maior aproveitamento da ferramenta e menor redução do tempo para troca da ferramenta. Além disso, ao aplicar os microcontroladores e sensores de baixo custo não invasivo é possível medir e adquirir o sinal online longe do chão de fábrica e não interferir no processo de fabricação.

## 1.1 OBJETIVO GERAL

Desenvolver um sistema inteligente para detectar a variação de dureza do material das peças durante a usinagem no processo de fresamento. .

## 1.2 OBJETIVO ESPECÍFICO

- a) Implementar um sistema de aquisição de dados para medição do sinal da corrente e sinais sonoros utilizando microcontroladores de baixo custo;
- b) Verificar se o sinal adquirido da pressão sonora e corrente são adequados para indicar a variação da dureza do material;
- c) Classificar o material por nível de dureza aplicando a máquina de vetor de suporte.

## 1.3 ESTRUTURA DA DISSERTAÇÃO

Essa dissertação consiste em cinco capítulos, conforme segue:

- **Capítulo 1: Introdução** – Este capítulo aborda uma breve contextualização do tema, enfatizado a problemática que motivou o desenvolvimento da pesquisa. Além disso, objetivo e os específicos;

- **Capítulo 2: Revisão Bibliográfica-** Neste capítulo será abordado sobre: o processo de fresamento, monitoramento na usinagem, aquisição do sinal e sistema inteligente, dando ênfase em máquina de vetor de suporte;
- **Capítulo 3: Materiais e métodos-** Neste capítulo será descrito os materiais, os equipamentos, os softwares, bem como a metodologia empregada e executada para a execução desse trabalho;
- **Capítulo 4: Resultados e discussões:-** Nesta etapa serão apresentadas as análises dos resultados obtidos nos ensaios experimentais e suas respectivas discussões da metodologia aplicada descritas no capítulo três;
- **Capítulo 5: Considerações finais -** Serão apresentadas as conclusões obtidas através dos resultados e discussões;
- **Capítulo 6: Referências:-** Aborda as principais referências para o desenvolvimento deste trabalho;

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 TECNOLOGIAS PRESENTE NA INDÚSTRIA 4.0

A revolução industrial é marcada por transformações ao longo da história devido a suas inovações (Figura 1). A primeira revolução industrial foi marcada pela primeira máquina a vapor; a segunda pela produção em massa e a energia elétrica; a terceira pela automatização industrial e a quarta, também conhecida por indústria 4.0 (ROZO-GARCÍA, 2020).

A indústria 4.0 está atrelada à produção inteligente, fundindo os sistemas físicos com os sistemas digitais gerando uma rede de produção que interagem entre si. O primeiro conceito da indústria 4.0 foi abordado pela primeira vez na Feira de Hanover na Alemanha, em 2011, para se referir à “fábrica inteligente”. A mesma está transformando as empresas tradicionais em indústrias inteligentes com o auxílio da computação em Nuvem, Internet das Coisas, Robôs Autônomos, Big Data, Manufatura Aditiva, Segurança Cibernética, Simulação, Realidade Aumentada e Integração Vertical e Horizontal de Sistemas de Informação, conforme é ilustrado na Figura 2 (ROZO-GARCÍA, 2020), (BRIZOLLA, 2019).

A internet das coisas (IoT do termo em inglês *Internet of Things*) permite a comunicação entre dispositivos interconectados, por exemplo, sistema industrial, dispositivos médicos, smartphones e entre outros que utiliza o serviço Web. A tecnologia IOT permite a obtenção *on-line* dos dados adquiridos pelos sensores, facilitando a tomada de decisão (FERRER et al., 2017).

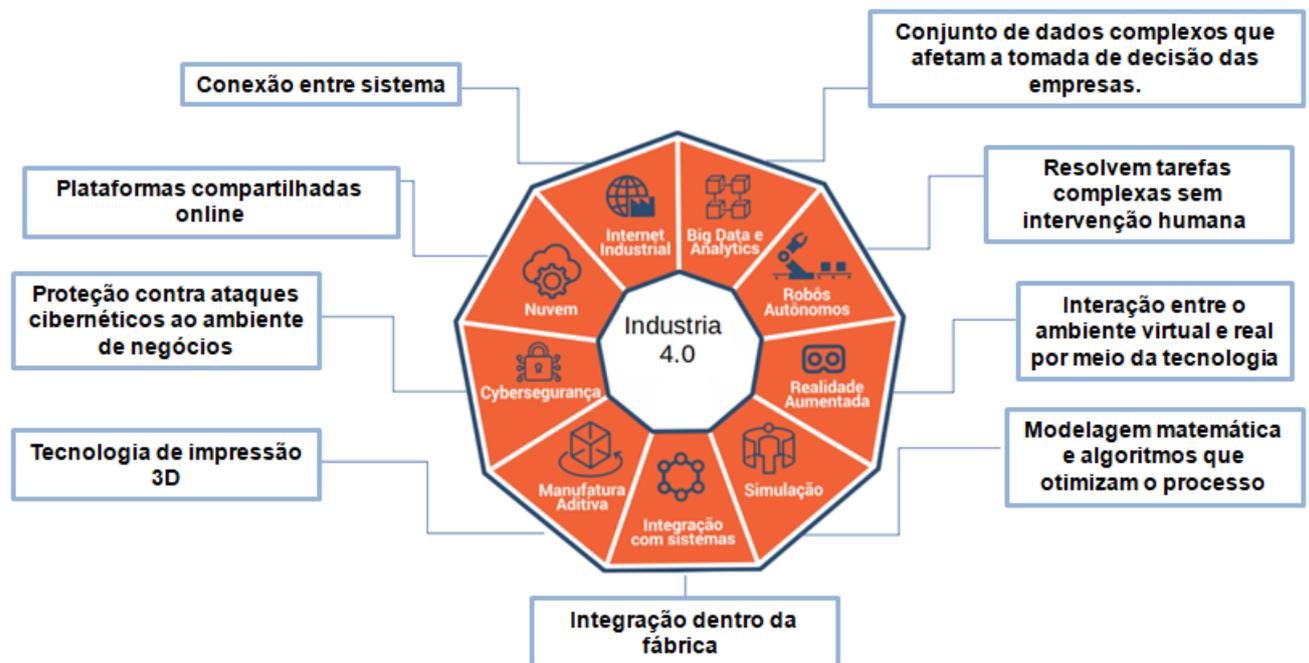
Mourtzis *et al.* (2018) implementaram a internet das coisas para o monitoramento do chão de fábrica, sendo que os dados monitorados eram transferidos para a nuvem para posterior

Figura 1 – Resumo das revoluções industriais.



Fonte: Brizolla (2019).

Figura 2 – Tecnologias presentes na Indústria 4.0.



Fonte: Adaptado de Ambhore (2015)

processamento e visualização usando uma topologia de rede de sensores. Eles avaliaram que o sistema proposto é validado para ser utilizado em laboratórios, pequenas e médias empresas na usinagem de peças e fabricação de moldes.

Além disso, Muraro *et. al* (2020) e Sousa (2017) estudaram o monitoramento do desgaste de ferramentas utilizando sensor de potência para medir a corrente do motor. Eles chegaram à conclusão que o uso dessa tecnologia tem um papel importante na eficiência do processo, pois a mesma auxilia na diminuição de falhas (MURARO, 2020), (SOUSA et al., 2017), (MOURTZIS; MILAS; VLACHOU, 2018).

A computação em nuvem também vem ganhando destaque nos processos de fabricação. Os sinais extraídos de sensores conectados às máquinas e equipamentos são enviados a computadores, por exemplo, via cabo ou rede *wi-fi*. Computadores longe do chão de fábrica processam os sinais, extraindo parâmetros, sem sofrer interferência (SOUZA, 2015), (KOTHURU; NOOKA; LIU, 2018).

Xu (2012) abordou que a computação em nuvem está viabilizando a troca de dados na indústria de manufatura, transformando uma manufatura tradicional em processos inteligentes para auxiliar na tomada de decisão com uma alta confiabilidade.

Existem estudos recentes que apresentam os benefícios da utilização da tecnologia em nuvem, tais como: identificar anomalias, detectar condição atual do sistema, facilitar manutenção, comunicação entre sensores (CAGGIANO, 2018), (THAMES; SCHAEFER, 2016), (XU, 2012)

(UHLMANN et al., 2017), (SUNNY; LIU; SHAHRIAR, 2018).

Em outra pesquisa, Mourtzis *et al.* (2016) abordaram o desenvolvimento da tecnologia em nuvem para o monitoramento e planejamento do processo de fabricação, considerando a disponibilidade da máquina-ferramenta através de sensores, entrada de operadores e programação da máquina. Unindo informações necessárias para processar os dados de monitoramento para alimentar o sistema de planejamento do processo com o status, especificações e informações do tempo de disponibilidade das máquinas ferramentas (MOURTZIS et al., 2016).

Cui *et al.* (2021) abordaram a principal vantagem do uso dessa tecnologia: prazos de entrega, volume de produção, customização em massa. Além disso, eles relataram que a integração da impressão 3D, computação em nuvem e redes inteligentes pode favorecer no aumento da customização em massa (CUI et al., 2022).

Outro pilar que vem ganhando destaque na indústria 4.0 é a integração do sistema. A integração do sistema é a união de todo ambiente corporativo, pois ocorre a interligação desde o sistema de gerenciamento até o chão de fábrica, facilitando na tomada de decisão (ERBOZ, 2017). A simulação é uma ferramenta importante, pois permite a criação de cópias fiéis de sistemas complexos, que podem ser previstos utilizando computadores, minimizando o custo e aumentando a confiabilidade. Como exemplo, pode-se citar a simulação de montagem de sistemas mecânicos em linhas utilizando robôs (ERBOZ, 2017).

## 2.2 FRESAMENTO

A usinagem é o processo de fabricação mais usado para converter a matéria-prima em sua forma final utilizando uma ferramenta de corte para remoção do material na forma de cavaco. O motivo para isso, é devido à versatilidade e a capacidade de trabalhar com geometria mais complexa. Entre os processos de usinagem, o que mais se destaca é o fresamento devido a sua flexibilidade e produtividade. O fresamento ocorre pela retirada de material da peça bruta utilizando ferramenta de corte em rotação que avança na direção da mesma, ou seja, o fresamento é um dos processos de usinagem, que utiliza fresa(ferramenta) que apresenta arestas cortantes dispostas simetricamente ao redor do seu eixo (DINIZ A. E; MARCONDES, 2013), (FERRARESI, 2018).

Diniz *et al.* (2013) classifica o processo de fresagem de duas maneiras: de acordo com a disposição dos dentes ativos da fresa (tangencial ou frontal) e a posição do eixo árvore da máquina-ferramenta (fresamento horizontal, fresamento vertical ou fresamento inclinado). No fresamento tangencial, as fresas utilizadas são cilíndricas ou tangenciais, sendo que o eixo da fresa é paralelo à superfície que está sendo gerada e os dentes ativos estão na superfície cilíndrica da ferramenta. Em contrapartida, no fresamento frontal as fresas empregadas frontais ou de topo, em que o eixo da fresa é perpendicular à superfície gerada e os dentes ativos estão na superfície frontal da ferramenta. Para não diminuir a vida útil da ferramenta ou até mesmo peças com acabamento superficial irregular, deve existir uma relação dos parâmetros envolvidos e trajetória

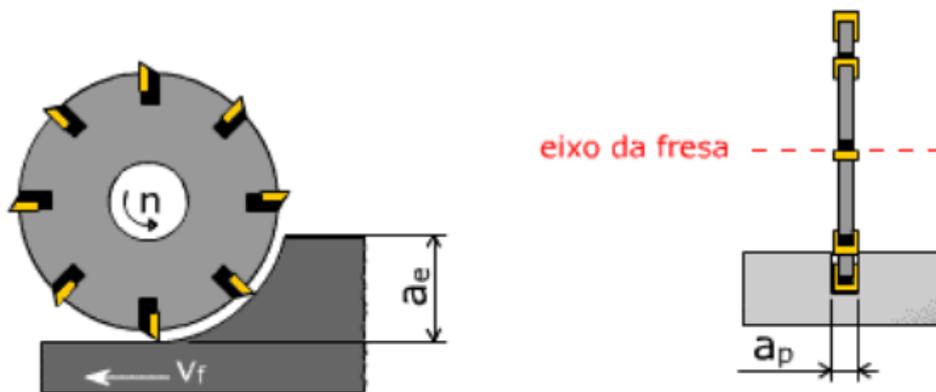
da ferramenta (concordante ou discordante).

### 2.2.1 Parâmetros de corte no fresamento

Os parâmetros de corte estão relacionados com a taxa de remoção do material, acabamento superficial, integridade superficial, desgaste da ferramenta de corte, etc. Por exemplo, o parâmetro de corte pode ser escolhidos de tal modo a atender as exigências de acabamento superficial, ondulação, visto que podem influenciar no comportamento dos componentes mecânicos (DINIZ A. E; MARCONDES, 2013),(CIMM, 2022).

A Figura 3 apresenta os parâmetros de penetração  $a_p$  e  $a_e$ .

Figura 3 – Parâmetro de corte



Fonte: CIMM (2022)

**Profundidade da usinagem ( $a_p$ ):** é a medida perpendicular em relação ao plano de trabalho. Sendo que, no fresamento tangencial é a largura de usinagem, já no fresamento frontal, está relacionado com a profundidade de penetração da ferramenta na peça. Desta forma, os fatores com influência sobre  $a_p$ : a potência da máquina, as vibrações, a rigidez da fixação da peça, a rigidez da própria peça e acabamento superficial.

**Penetração de trabalho ( $a_e$ ):** é a penetração da ferramenta no plano de trabalho e é perpendicularmente à direção de avanço

**Avanço por dente da fresa ( $f_z$ ):** é o percurso de avanço por dente, medido na direção do avanço, ou seja, distância linear estabelecida por um dente da ferramenta no intervalo na qual dois dentes consecutivos serão usinados na direção de avanço. Ao escolher  $f_z$ , vários fatores deve-se considerar o tipo de fresa, material da ferramenta, acabamento superficial, a potência da máquina, entre outros.

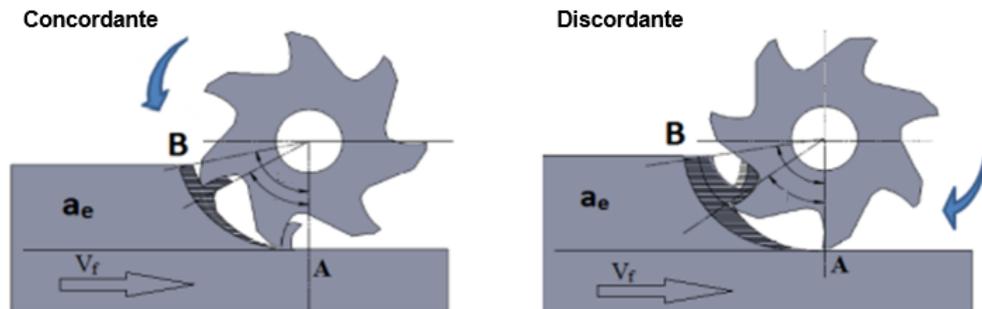
**Velocidade de avanço ( $V_f$ ):** é a quantidade de movimento em um determinado tempo.

**Velocidade de corte ( $V_c$ ):** é a velocidade tangencial instantânea sendo proveniente do movimento de rotação da ferramenta.  $V_c$  influencia no desgaste da ferramenta, temperatura de corte, potência da máquina. Desta forma, o aumento da  $V_c$  provoca o aumento da força de impacto entre a aresta de corte e a peça.

### 2.2.1.1 Sentido de corte

O sentido de corte pode influenciar na magnitude da força de corte durante a entrada da ferramenta na peça, na temperatura de usinagem e no desgaste da ferramenta. O sentido de corte pode ser discordantes ou concordante, como apresentado na Figura 4 (DINIZ A. E; MARCONDES, 2013), (ALMEIDA, 2019).

Figura 4 – Sentido de corte.



Fonte: Almeida (2019)

No fresamento concordante, Diniz *et al.* (2013) define que o sentido do movimento de avanço é o mesmo do sentido de rotação da fresa. A espessura de corte se inicia no máximo e vai reduzindo até sair do corte. É no início do corte que a espessura do cavaco tem seu valor máximo. Com isso, a ferramenta sofre seu maior carregamento no início do corte, ou seja, impactos.

Por outro lado, no fresamento discordantes o sentido do movimento de avanço e de rotação da fresa são contrários. A espessura do cavaco tem seu valor mínimo no início do corte, atritando na superfície da peça, antes da formação do cavaco. A ferramenta sofre maior desgaste, mas menos impactos devidos sua entrada no corte (ALMEIDA, 2019), (GARCIA, 2015).

### 2.2.2 Ferramenta de corte

A escolha do material da ferramenta de corte tem como principal exigência os custos de usinagem. Esse, por sua vez, está ligado à vida da ferramenta de corte e a qualidade superficial da peça usinada. Além disso, a seleção depende de vários fatores tais como, tipo do material a ser usinado, dureza da peça, condições da máquina-ferramenta, etc. Diniz *et. al* (2013), divide os materiais para ferramenta de corte em aços rápidos, aços rápidos com cobertura, metal duro, metal duro com cobertura, cerâmica, nitreto de boro cúbico (CBN) e diamante (FERRARESI, 2018).

A ferramenta de metal duro é a mais utilizada no processo de usinagem devido as suas propriedades mecânicas, tais como: dureza a temperaturas elevadas, tenacidade e resistência ao desgaste. Essas características são obtidas através seu processo de fabricação, ou seja, do processo de metalurgia do pó, sendo que, o pó carboneto de tungstênio (WC) são misturados em diferentes proporções com ligante cobalto (Co), obtendo-se com isso, propriedades distintas. São

ainda misturados carboneto de tântalo (TaC), carboneto de Titânio (TiC) e carboneto de nióbio (NbC) para a obtenção de classes de metal duro que são utilizados na usinagem de diferentes tipos de materiais. Esse ainda são na sua grande maioria revestidos, aumentando sua resistência ao desgaste (DINIZ A. E; MARCONDES, 2013), (FERRARESI, 2018).

### 2.3 MONITORAMENTO NA USINAGEM

O monitoramento consiste em avaliar ou acompanhar o processo. Os sistemas de monitoramento do processo podem ser *off-line* ou *on-line*. Um sistema *off-line* implica interromper o processo de usinagem e examinar o estado da ferramenta de corte usando equipamentos de inspeção como um microscópio óptico em períodos não regulares. Em sistemas *on-line*, o processo de usinagem não é interrompido, mas os parâmetros monitorados são medidos e relacionados ao estado da ferramenta de corte em intervalos regulados (MOHAMED et al., 2022).

Portanto, através da medição direta ou indireta verifica-se a condição do sistema. Na medição direta podem-se obter resultados mais precisos, porém se interrompe o processo para detectar anormalidades. Utiliza-se para medição, por exemplo, microscópio óptico para a medição de desgaste da ferramenta de corte, ou rugosímetro para a medição da rugosidade de uma peça. Por outro lado, na medição indireta se acompanha o mensurável em tempo real. Essas medições são realizadas por sensores como: sensores de potência, dinamômetros, acelerômetro, sensores de temperatura, sensores de emissão acústica (SOUZA, 2015); (KOTHURU; NOOKA; LIU, 2018).

Para que o processo de monitoramento obtenha êxito, deve seguir algumas etapas, conforme é exemplificado na Figura 5. Primeiramente definir qual o processo a ser monitorado. Em seguida, deve-se escolher o sensor mais adequado para o processo e como deve ser realizado o processamento do sinal. A extração de parâmetros é a uma etapa importante, pois correlaciona o sinal com as características nas quais se quer monitorar. E por último a escolha do sistema de inteligente adequado para a realização da classificação e com isso a tomada de decisão.

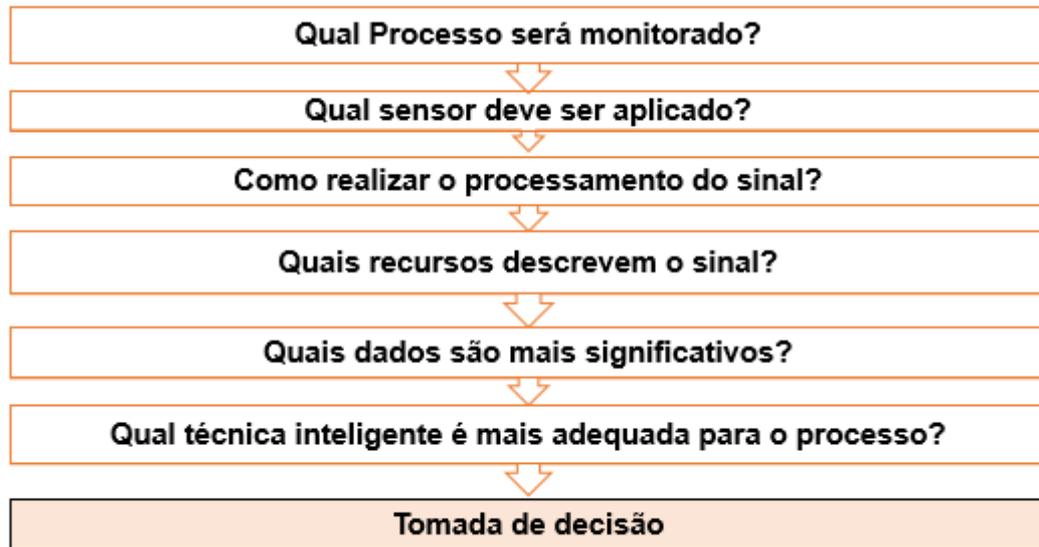
A Tabela 1, apresenta exemplos de medição empregados no monitoramento de processos de usinagem, classificando-os como métodos diretos e indiretos. Na mesma tabela é possível ver as grandezas medidas, as aplicações e os transdutores/sensores utilizados.

Desta forma, Abellan- Nebot e Subirón (2010), fizeram um levantamento bibliográfico em relação às vantagens e limitações da medição direta, indireta e suas aplicações na indústria. Abordaram que os dinamômetros são viáveis para detectar quebra da ferramenta, prever rugosidade da superfície e verificar o desgaste da ferramenta, em contrapartida, os sensores de potência são úteis para verificar a quebra da ferramenta e o desgaste da ferramenta (ABELLAN-NEBOT; SUBIRÓN, 2010).

Os métodos indiretos empregam os recursos extraídos de sinais como, por exemplo, força de corte, corrente do motor e sinais sonoros.

Diante disso, Zhou *et al.* (2022) abordaram em sua pesquisa vantagens e desvantagens de

Figura 5 – Metodologia para desenvolver sistema de monitoramento para processos de usinagem.



Fonte: Adaptado de Abellan-Nebot (2009).

se utilizar um dinamômetro para medir a força de corte. O seu lado positivo, de medir a força de corte, pois pode estimar com maior precisão o estado de da ferramenta de corte.

Em contrapartida, a aplicação de dinamômetros não é viável para ambientes de chão de fábrica, pois influenciam na rigidez do sistema e com isso na precisão da usinagem e são muito caros, aumentando o custo total de processo (ZHOU et al., 2020), (KOIKE; OHNISHI; AOYAMA, 2016).

Já com relação aos sensores de medição de corrente elétrica, segundo Zhou *et. al* (2022), esses são considerados mais práticos para serem empregados em oficinas industriais do que os dinamômetros para medir a força de corte. Portanto, estimar a força de corte através da medição da corrente do motor do eixo-árvore é uma solução mais viável que a utilização de um dinamômetro. (LIU; KILIC; ALTINTAS, 2022)

Silva *et al.* (2010) monitorou o desgaste da ferramenta no processo de fresamento medindo os sinais de potência. O mesmo observou que existem dois efeitos possíveis sobre a potência de corte na usinagem. O primeiro efeito estava relacionado com a redução da potência consumida devido aumento da temperatura na interface de corte e conseqüentemente uma diminuição da resistência do material, facilitando o processo de corte do material. Por outro lado, o segundo efeito estava relacionado ao aumento da área de contato entre a ferramenta e a peça em decorrência do desgaste da ferramenta. Esse aumento da área de contato resulta no aumento da força e da potência de corte, se sobrepondo à diminuição da resistência do material devido à elevação da temperatura na interface de corte. Eles chegaram a conclusão que esse método é viável para o monitoramento do processo, apesar do aumento potência de corte consumida durante a usinagem devido ao desgaste da ferramenta (SILVA, 2010); (CAMPIDELLI et al.,

Tabela 1 – Exemplos de métodos de medição.

<b>Métodos</b>	<b>Grandeza</b>	<b>Aplicação</b>	<b>Transdutor/Sensor</b>
<b>Direto</b>	Óptico	Contorno ou posição da aresta de corte (região desgastada).	Câmera CCD; sensor de fibra óptica; microscópio
	Distância ferramenta-peça	Distância entre a peça e a ferramenta ou suporte.	Micrômetro; transdutor indutivo(LVDT3), capacitivo ou ultrassom.
	Tamanho da peça	Dimensão da peça.	Micrômetros; transdutor: óptico, pneumático, ultrassom, eletromagnético.
<b>Indireto</b>	Potência	Detecção de quebra de ferramenta, diagnóstico de desgaste da ferramenta	Amperímetro; sensor de corrente; sensor de potência
	Vibração	Previsão de rugosidade da superfície, diagnóstico de desgaste da ferramenta,	Acelerômetro.
	Força de usinagem.	Diagnóstico de desgaste da ferramenta, detecção de quebra de ferramenta, previsão de rugosidade da superfície	Dinamômetros.
	Emissão acústica	Detecção de quebra de ferramenta, diagnóstico de desgaste da ferramenta	Transdutor Piezoelétrico.

Fonte: Adaptado de Abellan-Nebot (2009)

2020).

Existem muitos relatos na literatura, sobre a utilização da medição direta para medir a variação da dureza com base nos parâmetros de corte.

Por exemplo, Zurita - Hurtado *et al.* (2017) avaliaram a variação da dureza superficial de aço AISI 1020 com base em parâmetros de corte no torneamento. O estudo mostrou que o parâmetro de corte influencia na microdureza da superfície do material, ou seja, quando eles aumentaram o valor da profundidade de corte e a taxa de avanço consequentemente aumentou a força de corte. (ZURITA-HURTADO; GRACI-TIRALONGO; CAPACE-AGUIRRE, 2017).

Em outro estudo, Krolczyk *et al.* (2014) relatou que a velocidade de corte e o raio da aresta de corte influenciam na microdureza do material de trabalho (KROLCZYK; NIESLONY; LEGUTKO, 2014).

A não uniformidade da dureza pode acarretar, na diminuição da vida útil da ferramenta de corte, quebra inesperada da ferramenta e na rugosidade superficial. Portanto, essa problemática atrai a atenção da indústria, pois a mesma busca um monitoramento *online* para facilitar na troca da ferramenta durante a usinagem.

Kothuru *et al.* (2017) propôs a implementação do monitoramento inteligente utilizando três microfones, chegando à conclusão que os sinais sonoros são eficazes para detectar o desgaste da ferramenta e a variação de dureza da peça.

### 2.3.1 Monitoramento através da corrente do motor eixo-árvore

O monitoramento através da medição de corrente elétrica do motor do eixo-árvore tem a vantagem significativa de não influenciar diretamente o processo de usinagem, sendo muito fácil de ser utilizado. Liu *et al.* (2022) demonstraram que o aumento do sinal de corrente do motor está relacionado com o desgaste da ferramenta. Silva *et al.* (2021) estudaram a potência ativa no fresamento frontal utilizando um sistema de baixo custo. Eles observaram que o aumento da profundidade de corte e do avanço influencia no aumento da potência ativa, pois maior força de corte é necessário para remover material.

As máquinas-ferramenta modernas apresentam motores de acionamento independentes para os movimentos de corte e avanço. Desse modo, a medição da potência de corte pode ser realizada diretamente no motor elétrico do eixo-árvore da máquina, sem influência dos motores de acionamento (SILVA et al., 2021), (CAMPOS et al., 2014), (GIMENEZ, 2020), (SOUZA, 2019a)..

A potência de acionamento  $P_m$  é dado por:

$$P_m = \frac{P_c}{\eta}, \quad (1)$$

$P_c$  é a potência de corte e  $\eta$  o rendimento mecânico.

Desta forma,  $P_c$  pode ser calculada pela relação (ALEXANDER; SADIKU, 2013); (RECH et al., 2017):

$$P_c = F_c \cdot V_c, \quad (2)$$

No fresamento, a ferramenta tem uma velocidade tangencial  $V_c$  e a força de corte  $F_c$ , por sua vez, é calculada pela expressão

$$F_c = K_{c1.1} \cdot b \cdot Z_c \cdot h^{1-m_c}, \quad (3)$$

onde  $k_{c1.1}$  é a pressão específica de corte,  $b$  o comprimento da aresta ativa de corte,  $Z_c$  número de dentes ativos no corte e  $h$  a espessura do cavaco.

Segundo Alexander Sadiku (2013), a corrente nominal  $I$  em uma fase do motor trifásico pode ser calculada da seguinte forma:

$$I = \frac{P_m}{V \cdot \sqrt{3} \cdot \cos\theta} \quad (4)$$

onde,  $V$  é a tensão.

Substituindo a equação 3 em 2 e está em 1 e por último em 4 obtém-se a corrente do motor elétrico do eixo-árvore consumida durante o corte, definida pela relação matemática 5.

$$I = \frac{K_{c1.1} \cdot b \cdot Z_c \cdot h^{1-m_c} \cdot v_c}{V \cdot \sqrt{3} \cdot \eta \cdot \cos\theta}. \quad (5)$$

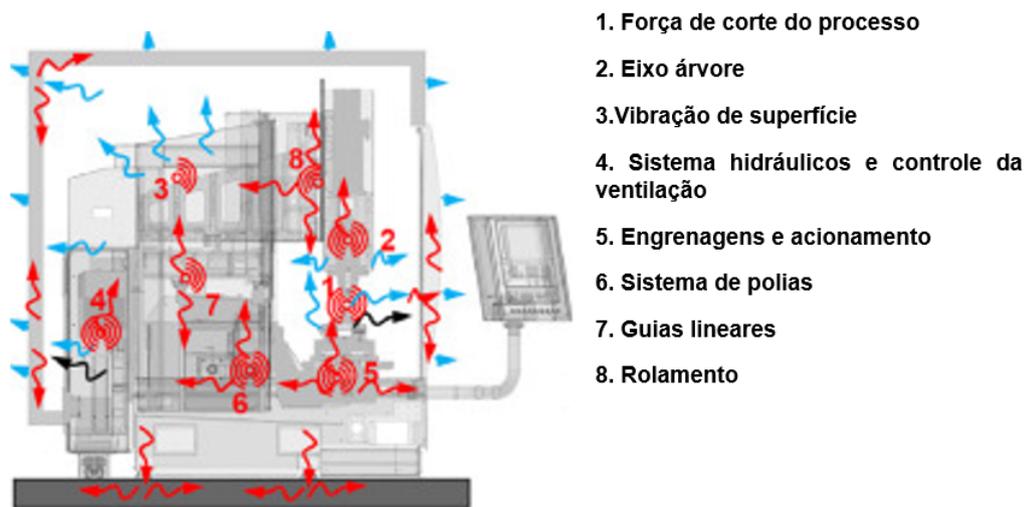
O aumento relativo da força de corte pode influenciar significativamente na variação da corrente do motor do eixo árvore. Por exemplo, se existirem alterações nas propriedades do material, isso irá impactar no  $K_{c1.1}$  e conseqüentemente na força de corte, alterando os valores da corrente.

### 2.3.2 Monitoramento através da pressão sonora

Os sinais sonoros gerados durante um processo de usinagem também são úteis para o monitoramento do processo. Segundo Wegener *et. al* (2021), a emissão de som ou ruídos inerentes da máquinas-ferramentas em funcionamento são causadas pelo sistema de acionamento elétrico, hidráulico, pneumático e pelo processo. Essas fontes podem ser diretas, quando são causadas por mecanismos fluidodinâmicos, como, por exemplo, pulsação na vazão do fluido, turbulência, jato de ar, choque de compressão, processos térmicos, etc. Ou indiretos, quando a emissão sonora é resultado da radiação do som transmitido pela estrutura, causada por vibrações estruturais devido à excitação mecânica, por exemplo, choque mecânico, desequilíbrio, inércia, forças magnéticas e entre outros e como tal, podem dar indicativos da condição da ferramenta de corte.

Diante disso, a Figura 6 exemplifica a emissão, transmissão e irradiação de ruído durante o funcionamento de um centro de usinagem. As principais fontes são 1- a força de corte do processo, 2- o eixo árvore, 3 — a vibração de superfícies, 4 – sistemas hidráulicos, controle e ventilação, 5- engrenagens e acionamento, 6 – sistema de polias, 7- guias lineares e 8 – rolamentos. O ruído gerado se propaga pela estrutura da máquina-ferramenta e da peça, atingindo a carenagem e com isso alcançando o exterior pelo ar e pelo solo (WEGENER et al., 2021).

Figura 6 – Exemplo de geração de ruído, transmissão e irradiação em um centro de usinagem.



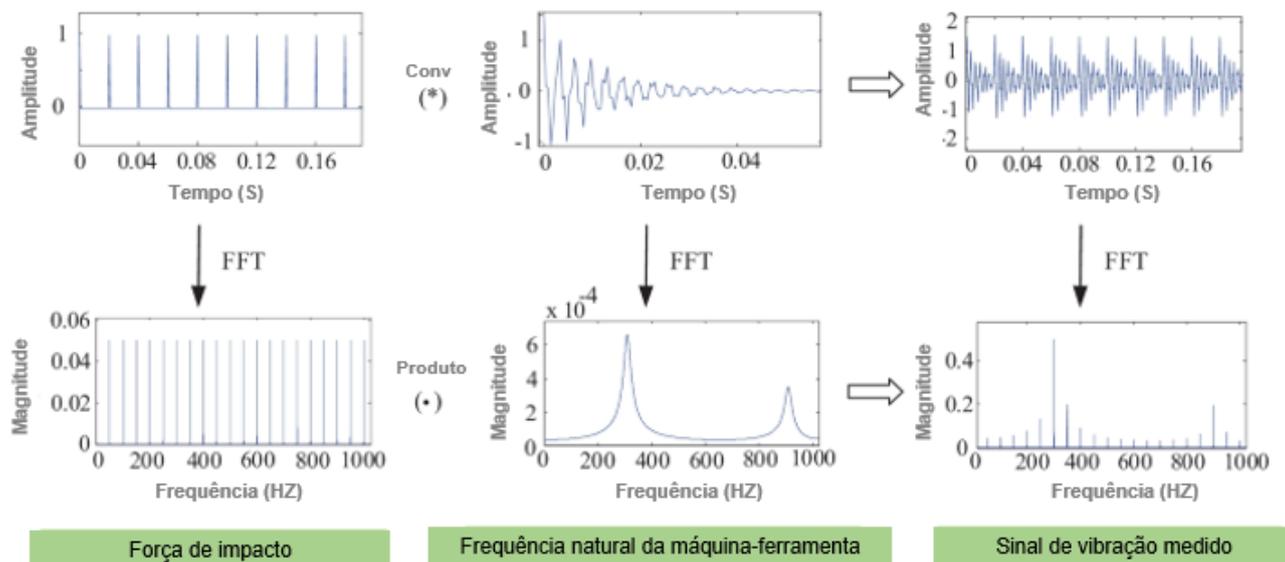
Fonte: Wegener *et. al* (2021)

O engajamento do dente da ferramenta no material da peça também leva ao surgimento de som, ou ruído, de duas maneiras. Na primeira, o impacto do dente da fresa excita a estrutura do sistema ferramenta/peça/sistema de fixação/máquina-ferramenta fazendo com que vibre. A vibração do sistema pode provocar uma variação nas propriedades do fluido no contorno produzindo as variações de pressão e densidade que irão provocar a propagação do som.

A característica dinâmica do sistema ferramenta/peça/sistema de fixação/máquina-ferramenta e a característica da força de corte são fundamentais para o surgimento do ruído no processo de corte. A Figura 7 exemplifica um sinal de força de corte no fresamento, que devido a uma baixa penetração radial, atua como uma força impulsiva, de curta duração, excitando a estrutura em uma ampla faixa de frequência. Com isso, um harmônico ou mais, pode coincidir com uma ou mais frequências de ressonância da estrutura, amplificando a vibração e com isso a pressão sonora nessas frequências. A variação de dureza da peça tende a modificar as forças de corte e com isso a amplitude das frequências de excitação, influenciando na pressão sonora (HE; NI; WANG, 2022).

A segunda fonte sonora é devido à formação do cavaco, por exemplo, o efeito do atrito, efeito da adesão e descolamento do cavaco sobre a ferramenta, deformação plástica do material, fratura, colisão do cavaco, bem como possível a mudança de fase. Esses efeitos geram o que são

Figura 7 – Exemplo do processo de produção de um sinal de vibração simplificado.



Fonte: He; Ni; Wang (2022)

chamados de “emissão acústica”, o que são entendidas como ondas elásticas que se propagam na superfície do sistema na faixa de frequência em torno de 20-2000 Hz. Essas ondas podem ser captadas por sensores de emissão acústica instalados diretamente na estrutura do sistema, ou é possível também capturar com microfones algumas faixas de frequência que são propagadas para o ar (PANDIYAN et al., 2022).

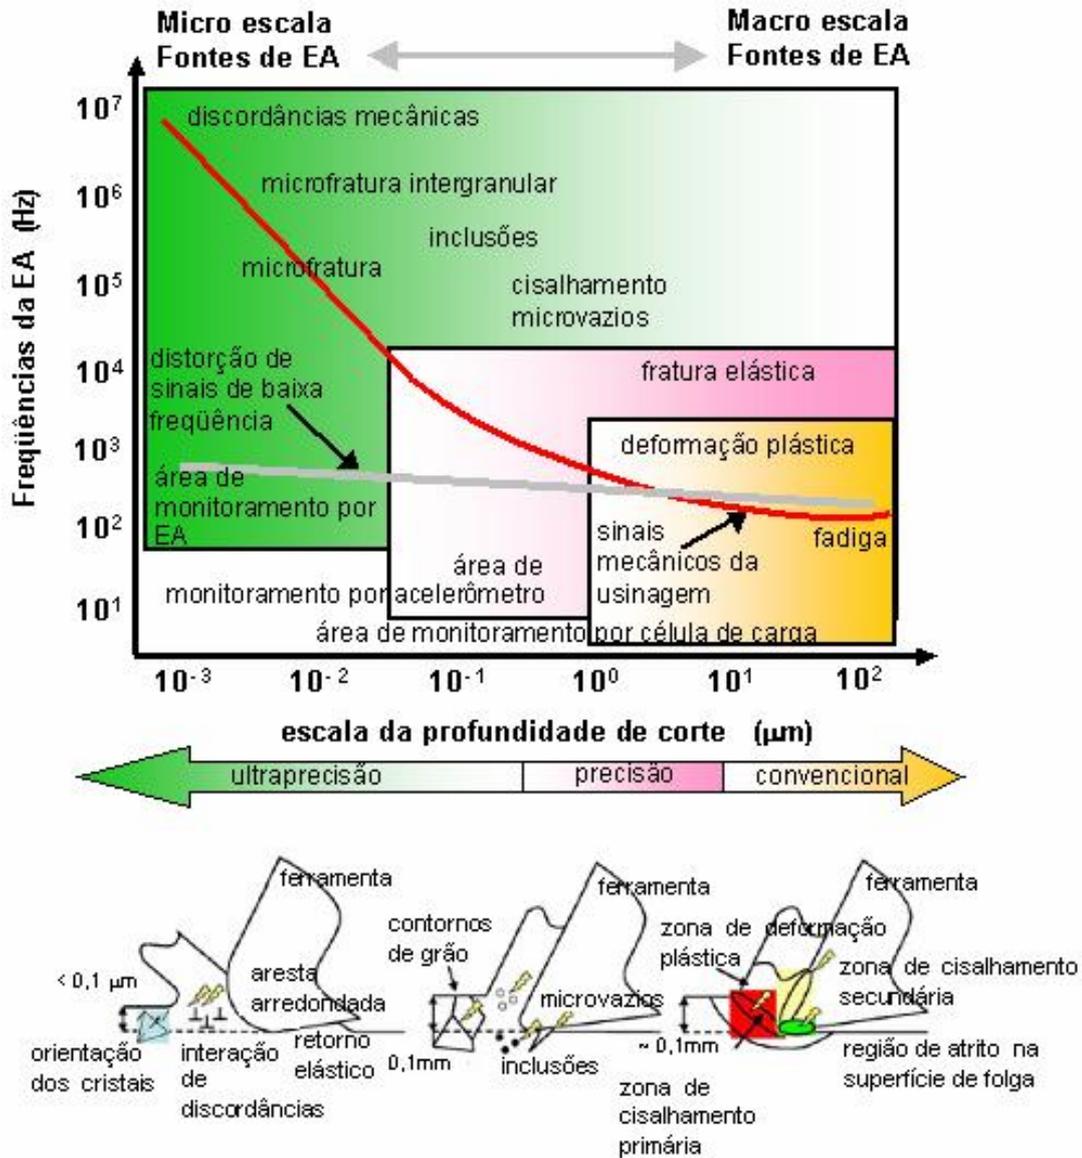
A Figura 8 apresenta a frequência da “Emissão Acústica” em função da profundidade de penetração para os processos de usinagem convencional, de precisão e de ultraprecisão.

Fontes de emissão acústica incluem os mecanismos de deformação e fratura, tais como: crescimento de trincas, movimento de discordâncias, maclação, deslocamento de contornos de grão, fratura e decoesão de inclusões, que por sua vez, tem relação direta com a propriedade do material da peça. Desse modo, qualquer variação na dureza da peça terá influenciada na frequência e a amplitude de vibração do som emitido (WEGENER et al., 2021).

Kothuru *et al.* (2017) e Raja *et al.* (2011), estudaram o monitoramento da condição da ferramenta utilizando as informações adquiridas através do som. Por exemplo, Lu *et al.* (2012), desenvolveram uma técnica para o monitoramento do desgaste da ferramenta com base na análise do sinal sonoro. Eles trabalharam com uma faixa de frequência entre 20kHz e 80kHz. A faixa de frequência em torno de 40kHz foi mais apropriada para detectar a condição da ferramenta. Em contrapartida, a frequência abaixo de 20kHz não apresentou bons resultados (LU; WAN, 2013), (RAJA et al., 2011).

Por outro lado, Rafezi *et al.* (2012), desenvolveram uma técnica para análise do desgaste da ferramenta e observaram que os componentes de frequência menores que 10 kHz são afetados pelo desgaste da ferramenta e também analisaram a influência do ruído na análise do sinal,

Figura 8 – Fontes de emissão acústica em vários estágios de remoção de material.



Fonte: Adaptado de Wegener *et al* (2021)

chegaram a conclusão que espectro de frequência do ruído nas proximidades da máquina-ferramenta tem componentes de frequência menores que 2 kHz (RAFEZI; AKBARI; BEHZAD, 2012).

Além disso, Zhou *et al.* (2020), investigou o monitoramento da condição de desgaste da ferramenta usando som no processo de fresamento. Chegaram a conclusão que, os recursos extraídos nos domínios do tempo e da frequência estão relacionadas com a condição de desgaste da ferramenta e a técnica que ele utilizou é viável para verificar o estado da ferramenta de corte.

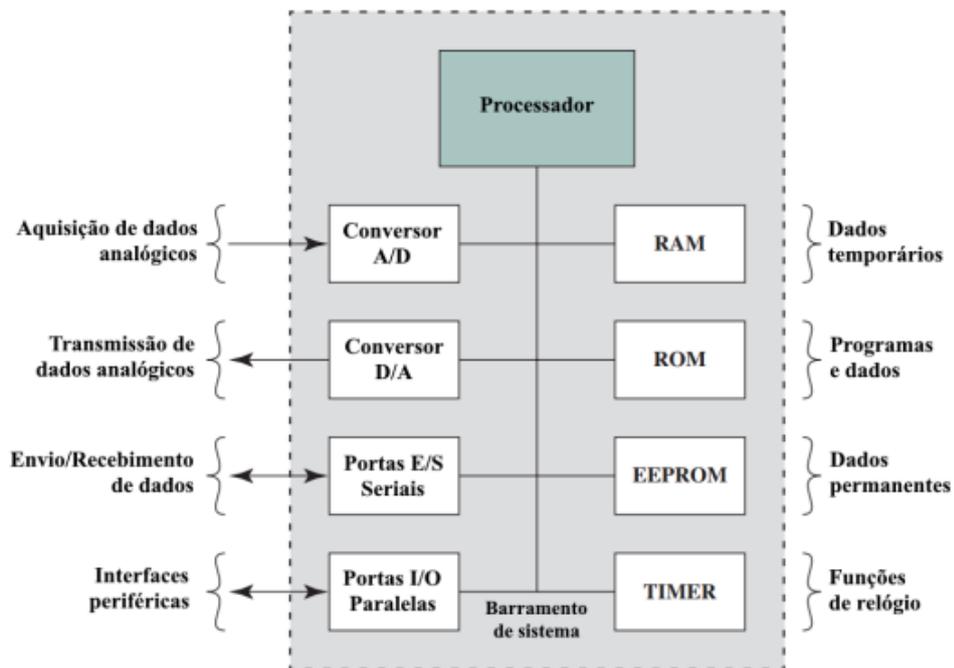
## 2.4 AQUISIÇÃO DE SINAL

O sistema de monitoramento inteligente vai desde a detecção do sinal até o diagnóstico para tomada de decisão. Por exemplo, sensoriamento, pré - processamento, tratamento do sinal e a tomada de decisão (SOUZA, 2015), (KOTHURU; NOOKA; LIU, 2018).

### 2.4.1 Microcontroladores

Um microcontrolador pode ser considerado como um pequeno computador num único circuito integrado o qual contém um núcleo de processador, memória e periféricos programáveis de entrada e saída (SANTOS et al., 2020). A Figura 9 apresenta uma estrutura básica de um microcontrolador tais como, processador baseado na arquitetura RISC, memória ROM, um sistema de *clock* e uma unidade de controle para entrada e saída, conversor A/D, conversor D/A, etc (LIMA, 2021).

Figura 9 – Estrutura básica de um microcontrolador.

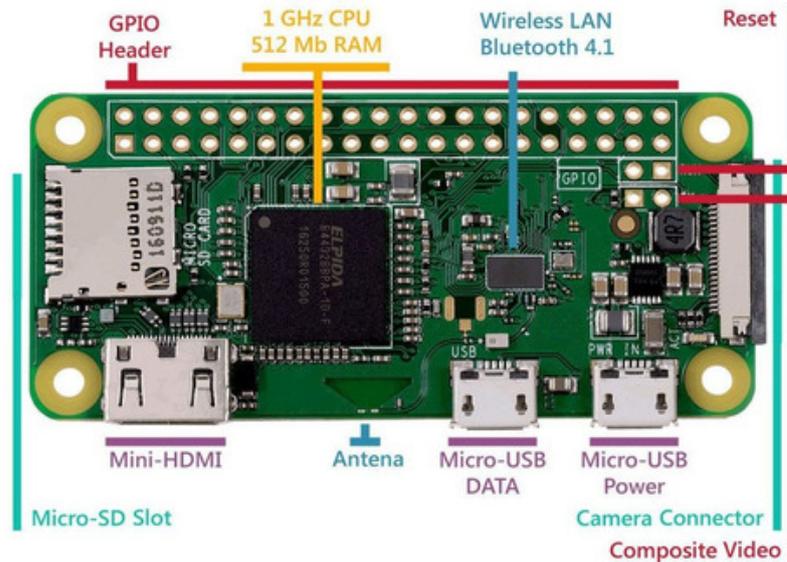


Fonte: Lima (2021)

Devido ao seu custo/benefício e confiabilidade é muito utilizado em sistemas de controle de processos, sistemas de controle de motores de automóveis, sistemas de controle remoto, dispositivos de instrumentação industrial, voltímetros, equipamentos de escritório e aparelhos eletrônicos. Arduino, ESP32 e Raspberry Pi são exemplos de microcontroladores bastante utilizados nos dias atuais em diversas áreas (SANTOS et al., 2020).

A Figura 10 apresenta um microcontrolador Raspberry Pi Zero. O mesmo podem ser aplicados quando necessita de altas taxas de processamento. O Raspberry Pi, pois tem a vantagem

Figura 10 – Placa Raspberry Pi.

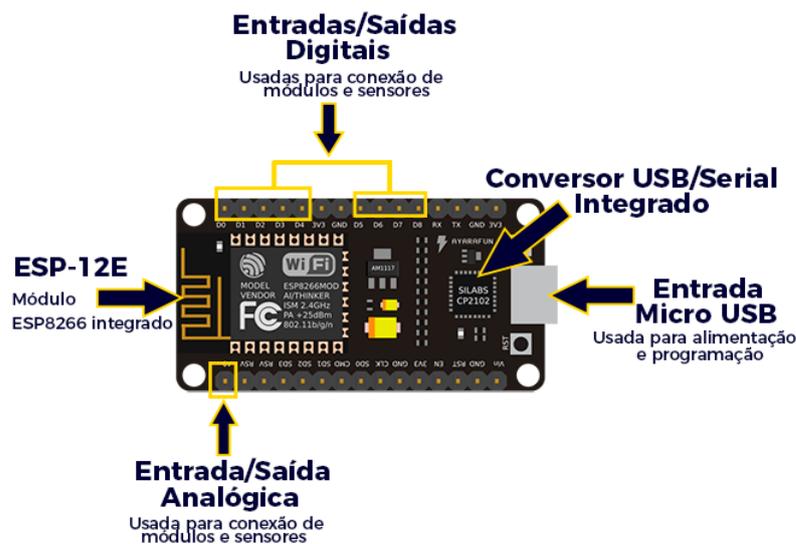


Fonte: Robótica (2022)

de armazenamento de dados em cartões de memória SD e os dados podem ser acessado por *wi-fi*. Além disso, a programação recomendada é o Python (LIMA, 2021), (ROBÓTICA, 2022).

Por outro lado, o microcontrolador *ESP8266* apresenta vários módulos integrados em algumas placas de desenvolvimento, por exemplo, o módulo *ESP8266 NodeMcu ESP-12E* com *wi-fi*, Figura 11. Ele tem funcionalidades semelhantes ao Raspberry Pi, mas com menor poder de processamento e armazenamento e de menor custo (OLIVEIRA, 2016), (LIMA, 2021).

Figura 11 – Placa ESP 8266.

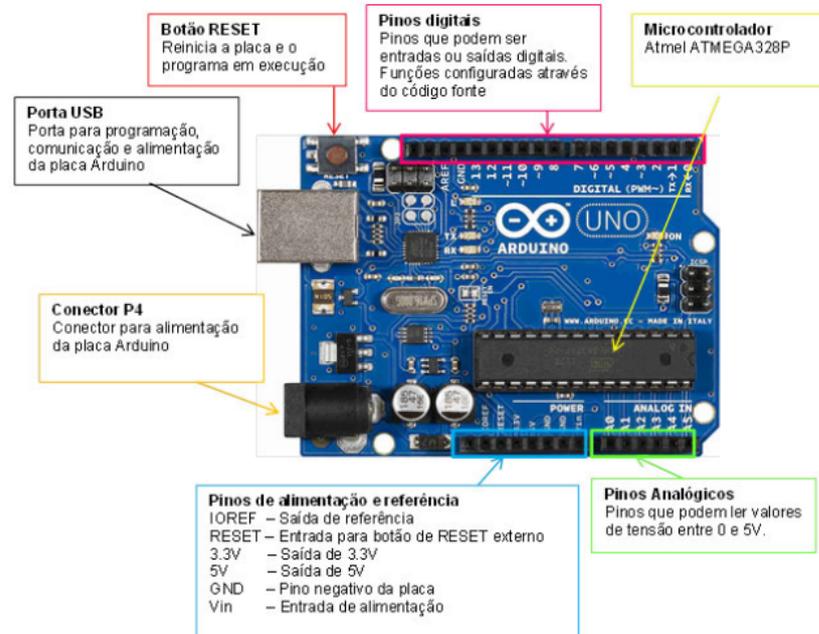


Fonte: Oliveira (2022)

O arduino (Figura 12) possui menor velocidade processamento comparado ao Raspberry

Pi e ao *ESP8266* e é programável na linguagem *C/C++* (LIMA, 2021), (BAU, 2018).

Figura 12 – Arduino Uno.



Fonte: Bau (2018)

A Tabela 2 apresenta uma análise comparativa entre os 3 microcontroladores apresentados como memória flash.

Tabela 2 – Comparação entre as placas Arduino, Raspberry Pi Zero e ESP8266.

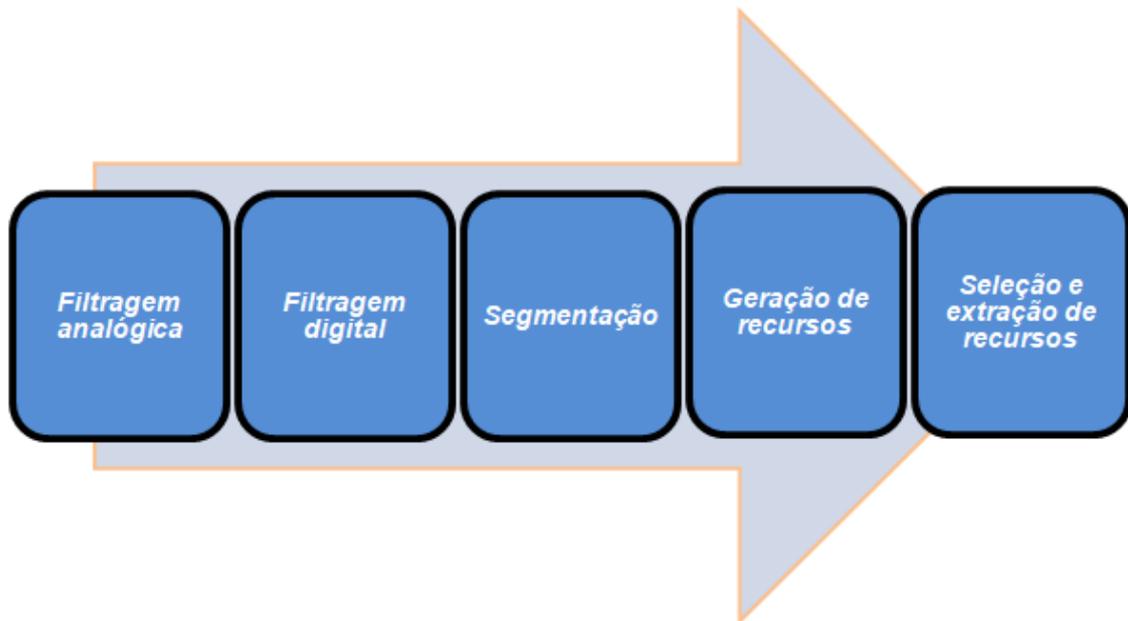
Especificações	Raspberry Pi zero	ESP8266	Arduino
Processador/ Microcontrolador	Broadcom BCM2837B0, Cortex-A53 64-bit	Tensilica L106 ultra-low power 32-bit	ATmega2560 RISC com até 16 MIPS
Memória FLASH	Varia conforme o cartão micro SD acoplado	4MB	256 KB

Fonte: Elaborada pela autora (2022).

#### 2.4.2 Processamento do sinal

Uma excelente estratégia no processamento do sinal é uma etapa obrigatória antes de selecionar ou extrair dados, pois o alto nível de ruído relacionado ao sinal produzidos devido ao ruído mecânico, elétrico e acústico na indústria pode influenciar no resultado (KOTHURU; NOOKA; LIU, 2018). Nesse contexto, Abellan-Nebot dividiu o processamento do sinal em 5 etapas.

Figura 13 – Processamento do sinal.



Fonte: Adaptado de Abellan-Nebot, (2009)

Conforme pode ser observado na Figura 13 essas etapas são:

- **Filtragem analógica:** O processamento do sinal bruto. Por exemplo, o sinal adquirido é filtrado para ser mantido na faixa de resposta frequência do sensor, evitando *aliasing* (distorção do sinal na aquisição).
- **Filtragem digital:** Faixa de frequência de interesse. Costa, (2018) aponta que a filtragem digital é uma rotina matemática em hardware ou software que opera sobre um sinal discreto e tem como resultado uma saída discreta. A mesma é requisitada em muitas aplicações quando se deseja filtrar o sinal adquirido para evitar ruídos de alta frequência e oscilações do sinal, provocado por algum evento mecânico transitório, tais como, quebra de uma aresta ou variação da dureza da peça em determinados pontos. A depender da característica do espectro selecionado, o filtro pode ser: passa-baixa, passa-alta, passa-faixa ou rejeita-faixa (COSTA, 2018).
- **Segmentação:** Intervalo de sinal de interesse. Por exemplo, pode ser aplicada para extrair informações adquiridas do sinal da força de corte durante a remoção do material.
- **Geração de recursos:** Transforma o sinal digital em recursos. Existem diferentes técnicas para geração de recurso tais como domínio do tempo, da frequência e Wavelet (KOTHURU; NOOKA; LIU, 2018).
- **Seleção e extração de parâmetros:** Essa etapa está relacionada com a extração dos recursos adquiridos depois do pré-processamento de sinal, resultando em um modelo de

previsão mais simples e mais confiável. Por exemplo, as técnicas de análise de sinais no domínio do tempo destacam-se, devido à sua aplicabilidade em facilitar a análise do sinal e igualmente útil na análise do desgaste de ferramentas de corte, rugosidade, falhas nos mancais de rolamento, etc.

### Parâmetros estatísticos no domínio do tempo

A maioria dos autores utiliza a raiz do valor quadrático médio RMS (*root mean square*), valores de pico, desvio padrão para seleção das características dos sinais no processo de monitoramento. Além disso, Silva, (2010) apresenta uma análise, comparando os parâmetros estatísticos dos sinais de potência e emissão acústica, como: curtose, coeficiente de assimetria (*skewness*), média, desvio padrão, variância, pico, RMS e fator de crista que melhor se correlacionavam com o desgaste da ferramenta de corte. O autor demonstrou que dentre esses os parâmetros estudados para o sinal de EA, apenas o *skewness* teve a melhor relação com o desgaste da ferramenta.

Vitória (2016) analisou, no domínio do tempo, os parâmetros RMS, curtose, pico e fator de crista do sinal de vibração gerado no fresamento do aço SAE 4340 medindo o sinal da vibração com o acelerômetro unidirecional. Os parâmetros RMS e curtose foram os que melhor indicaram a melhor correlação com o desgaste da ferramenta de corte (VITÓRIA, 2016), (SILVA, 2010), (ALMEIDA, 2007).

- Valor de Pico

O valor de pico é o nível máximo registrado no sinal, podendo ser definido pela Equação (6). Ele é importante quando se tem valores críticos de folgas, ou para indicar o valor máximos de sinais transientes (de curta duração) em choques e entre outros (WANG et al., 2018), (ALMEIDA, 2007).

$$Pico(x_p) = \max|x_i| \quad (6)$$

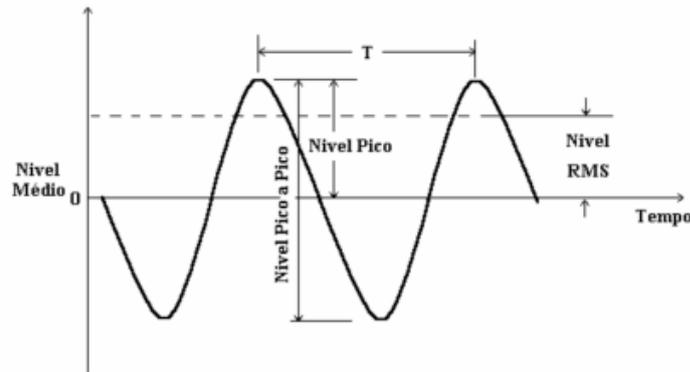
- RMS

Por outro lado, o valor eficaz ou RMS (*Root Mean Square*) está relacionado ao nível de energia de um dado sinal, ou de vibrações de um dado sistema. O mesmo pode ser considerado como a medida mais relevante para definir a amplitude de vibração. O Valor de RMS de um sinal discreto  $x_i$  pode ser calculado pela relação 7 (CAESARENDRA; TIAHJOWIDODO, 2017), (BORITH et al., 2020), (ALMEIDA, 2007).

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (7)$$

Um exemplo de sinal harmônico pode ser constatado na Figura 14. Nela é possível também observar o valor RMS do sinal, o valor de pico e o valor de pico a pico (ALMEIDA, 2007), (VITÓRIA, 2016).

Figura 14 – Quantificação do sinal harmônico.



Fonte: Vitória (2016)

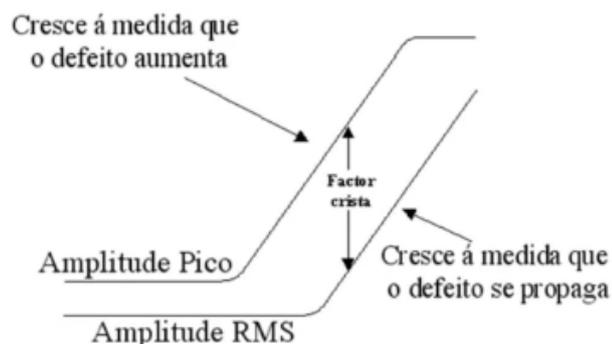
- Fator de crista

O fator de crista é a razão entre o valor de pico e o RMS do sinal. Esse parâmetro permite detectar falhas, pois indica o grau de homogeneidade do sinal no determinado período. Por exemplo, no processo de usinagem é possível observar a tendência da amplitude do sinal de vibração, do sinal da corrente do motor eixo-árvore entre outros. (CAESARENDRA; TJAHJOWIDODO, 2017), (ALMEIDA, 2007), (VITÓRIA, 2016). O fator de crista é calculado pela relação

$$F_c = \frac{X_p}{X_{rms}} \quad (8)$$

Na Figura 15 nota-se característica existente na forma de onda a medida que aumenta a vibração do sistema (VITÓRIA, 2016) aumenta o defeito e a relação do fator de crista com o valor de pico e RMS (AROEIRA, 2020).

Figura 15 – Variação dos valores de Fator de Crista em função da variação dos valores de pico e RMS .



Fonte: Aroeira (2020)

- Curtose

O parâmetro Curtose varia com base na dispersão dos dados, ou seja, indica o grau de achatamento da função de distribuição de probabilidade do sinal, Equação 9 (VITÓRIA, 2016), (SOUZA, 2019 b), (CAESARENDRA; TJAHJOWIDODO, 2017).

$$K = \frac{\sum_{i=1}^N [(x_i - \bar{x})^4]}{(N - 1)\sigma^4}, \quad (9)$$

onde  $x_i$  é a amplitude instantânea do sinal,  $\bar{x}$  é a média do sinal temporal,  $\sigma$  é o desvio padrão do sinal e  $N$  é o tamanho amostra.

- Coeficiente de assimetria

Coeficiente de assimetria (*skewness coefficient*) representa a simetria da distribuição de dados, e os valores negativos são assimétricos e indica os dados que estão à esquerda e valores positivos para a assimetria à direita (Equação 10) (SOUZA, 2019 b), (CAESARENDRA; TJAHJOWIDODO, 2017).

$$S = \frac{\sum_{i=1}^N [(x_i - \bar{x})^3]}{(N - 1)\sigma^3} \quad (10)$$

## 2.5 SISTEMAS INTELIGENTES

Com a crescente necessidade da indústria em otimizar e automatizar os processos de manufatura, e devido à inserção da internet das coisas, maior quantidade de dados estão sendo gerados. Com isso, a inteligência artificial vem ganhando destaque para analisar os dados adquiridos no processo de monitoramento de equipamento (OUADAH; ZEMMOUCHI-GHOMARI; SALHI, 2022), (KOTHURU; NOOKA; LIU, 2018).

Nesse contexto, algoritmos de aprendizado tem atraído muita atenção, auxiliando na resolução de problemas reais, através de simulação envolvendo elevado número de variáveis. Por exemplo, o reconhecimento de imagem, voz, predição da dureza de material de peças, classificação de rugosidade, dentre outros (OUADAH; ZEMMOUCHI-GHOMARI; SALHI, 2022)

O conjunto de dados para alimentar o algoritmo são divididos em dados de treinamento e teste. O algoritmo aprendem a característica do modelo com o conjunto de dados do treinamento, os dados de teste são utilizados para verificar a eficácia do modelo. Essa técnica pode ser usado tanto para classificação (classificação por categoria), quanto para regressão (preditor próximo aos dados das amostras) Entre as técnicas para classificação e regressão pode-se citar; rede neural artificial (RNA), árvore de decisão, máquina de vetor de suporte (SVM), k vizinho

mais próximo (KNN), dentre outros (KOTHURU; NOOKA; LIU, 2018),(KRISHNAKUMAR; RAMESHKUMAR; RAMACHANDRAN, 2018), (BRUSAMARELLO et al., 2022).

O algoritmo árvores de decisão tem por característica agrupam atributos de acordo com seus valores, e tem como padrão um gráfico que representa árvore sendo composta de nós e ramos. Cada nó representa atributos em um grupo a ser classificado, e cada ramo representa um valor que o nó pode assumir e é possível visualizar condições alcançar os resultados (OUADAH; ZEMMOUCHI-GHOMARI; SALHI, 2022).

Por outro lado, o algoritmo KNN tem por objetivo encontrar semelhança entre os dados mais próximos. Isto é os dados de entrada inclui k mais próximo dos conjuntos de dados de treinamento e medem a distância das variáveis. Quanto mais próximos o conjunto de dados, mais semelhante são (OUADAH; ZEMMOUCHI-GHOMARI; SALHI, 2022).

Em contrapartida, RNA é um sistema constituído por um conjunto de neurônios interconectados, aplicado para auxiliar na resolução de problemas tendo os dados de entrada (variável independente) e a saída (variável dependente) (OUADAH; ZEMMOUCHI-GHOMARI; SALHI, 2022), (KOTHURU; NOOKA; LIU, 2018).

RNA pode ser definido como uma técnica computacional baseada em uma lógica matemática tirando a ideia da característica dos neurônios biológicos, sendo composto por três camadas distintas: camada de entrada, camada oculta (onde ocorre o processamento) e camada de saída onde são gerados os resultados. Em que, os dados de entrada têm um peso associado a si que determina sua intensidade, ou seja, os neurônios da camada oculta e da camada de saída multiplicam cada sinal de entrada por pesos em que utiliza uma função de ativação para determinar sua saída (PONTES, 2011), (OUADAH; ZEMMOUCHI-GHOMARI; SALHI, 2022).

Já o algoritmo SVM está relacionado com a separabilidade das classes através de um hiperplano. Além disso, a depender da aplicações do SVM tem um comportamento melhor que RNA e são capazes de substituí-las. Por exemplo, Çaydas *et. al.* (2012) relatou que SVM superou RNA para a previsão da rugosidade no processo de torneamento CNC (ÇAYDAŞ; EKICI, 2012). Krishnakumar *et. al.* (2018), comparou SVM, árvores de decisão, naive bayes e rede neural artificial para classificar a condição da ferramenta de corte no processo de usinagem e constatou que SVM com os sinais de emissão acústica e vibração teve melhor desempenho. Asilturk *et. al.* (2012), aplicou redes neurais e regressão vetorial de suporte (SVR) para prever a rugosidade da superfície e a força de corte com base nas vibrações e no ângulo do perfil da pastilha. Quando compararam RNA e SVR observaram ambos os modelos teve um bom desempenho, porém o coeficiente de determinação de SVR foi de 92,7% tendo uma boa acurácia.

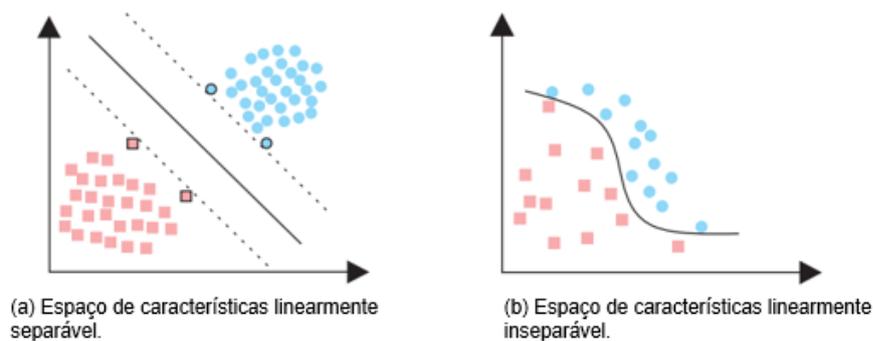
Portanto, existe vários relatos na literatura que SVM tem superado RNA (KRISHNAKUMAR; RAMESHKUMAR; RAMACHANDRAN, 2018), (KOTHURU; NOOKA; LIU, 2018),(ASILTURK; KAHRAMANLI; MOUNAYRI, 2012),(BORITH et al., 2020). Esta eficiência está relacionada com a definição dos parâmetros na fase de modelagem, pois o mesmo busca maximizar a capacidade de generalização e minimizar os erros (NIU; DAI, 2017).

### 2.5.1 Máquina de vetor de suporte

Máquina de vetor de suporte foi inicialmente proposto por Vapnik em 1995 e tem por objetivo, separar dados em duas classes usando uma função induzida com base no conjunto de dados e encontrar o classificador que minimiza o erro esperado, maximizando a margem de separação entre os pontos mais próximos. (BRUSAMARELLO et al., 2022), (NEGRI, 2013).

Portanto, aplicar um hiperplano, que diferencia muito bem as classes que são linearmente separáveis. A ocorrência de um hiperplano faz com que exista a separação de duas classes positivas e negativas, conforme exemplifica a Figura 16 (a)(BRUSAMARELLO et al., 2022). Porém, existem bases de treinamento que não podem ser separados somente por hiperplanos, neste caso são SVM linearmente não separável. Para transformar esse conjunto de dados em linearmente separável é necessário aplicar uma função matemática, por exemplo, a função Kernel, Figura 16 (b)(BRUSAMARELLO et al., 2022).

Figura 16 – Aplicação de SVM.

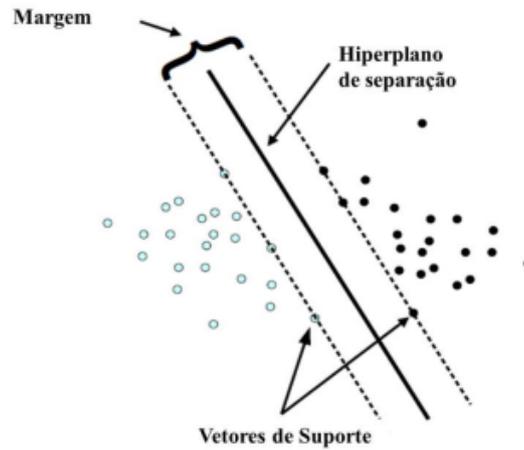


Fonte: Brusamarello *et al.* (2022)

A função kernel converte o problema não separável em problema separável, baseando nas transformações de dados extremamente complexas através do mapeamento para um espaço de maior dimensão. A probabilidade de trabalhar com dados linearmente não separáveis são mais altas (SCHÖLKOPF et al., 2002), (SOUZA, 2019 b).

Na Figura 17 fica mais evidente o objetivo do SVM, separar os dados em duas classes (pontos nas cores preta e azul) através do hiperplano de separação. Os hiperplanos são, então, as fronteiras de separação das classes e estes podem ter diferentes formas. Os pontos mais próximos do hiperplano são chamados vetores de suporte. A distância entre os vetores de suporte e o hiperplano, por sua vez, são chamados margem (SOUZA, 2019 b), (NEGRI, 2013), (BRUSAMARELLO et al., 2022).

Figura 17 – Linearmente separável.



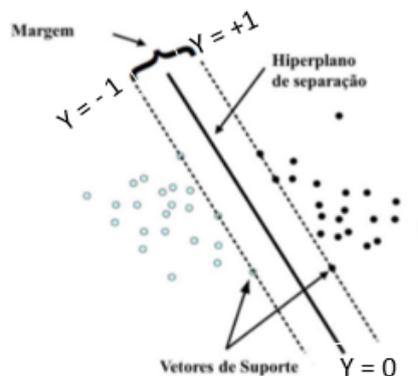
Fonte: Souza (2019 b)

O modelo SVM é dividido em linearmente separáveis linearmente não separáveis. Sendo que, SVM linearmente separáveis se dividem em duas categorias, os de margens rígidas e de margens suaves (LORENA; CARVALHO, 2007), (SANTOS, 2019).

### 2.5.2 SVM lineares com margens rígidas

Seja  $T$  (Figura 18) um conjunto de dados para treinamento com  $n$  dados  $x_i \in X$  sendo seus respectivos rótulos  $y_i \in Y$ . Portanto,  $X$  constitui o espaço de entrada dos dados e  $Y = -1, +1$  são as possíveis classes. Deste modo,  $T$  pode ser considerado linearmente separável se for possível separar os dados das classes  $+1$  e  $-1$  por um hiperplano e  $Y = 0$  a margem sendo definida como a distância entre as fronteiras de decisão (SOUZA, 2019 b) (LORENA; CARVALHO, 2007); (FRIGIERI, 2016).

Figura 18 – Hiperplano de separação.



Fonte: Adaptado de Souza (2019a)

Desta forma, para obter o hiperplano que é proporcional a margem de separação entre dois conjuntos de dados pode ser considerado uma relação de distância entre ponto e reta (NEGRI, 2013). Portanto, a equação de um hiperplano pode ser definida por (NEGRI, 2013), (SCHÖLKOPF et al., 2002); (LORENA; CARVALHO, 2007), (CAMPBELL, 2001):

$$f(x) = w \cdot x + b = 0, \quad (11)$$

onde  $w$  é um vetor normal ao hiperplano,  $w \cdot x$  o produto escalar entre os vetores  $w$  e  $x$ ,  $|b|$  a distância perpendicular do hiperplano à origem e  $\|w\|$  a norma Euclidiana de  $w$  (LORENA; CARVALHO, 2007), (SOUZA, 2019 b).

Com base na Equação 11, a mesma divide o espaço dos dados  $w$  em duas regiões:  $w \cdot x + b > 0$  e  $w \cdot x + b < 0$ . Uma função sinal  $g(x) = \text{sgn}(f(x))$  pode então ser empregada para a obtenção da classificações, conforme Equação 12, (LORENA; CARVALHO, 2007).

$$g(x) = \text{sgn}(f(x)) = \begin{cases} +1 & \text{se } w \cdot x + b > 0 \\ -1 & \text{se } w \cdot x + b < 0 \end{cases} \quad (12)$$

A partir de  $f(x)$ , é possível obter um número infinito de hiperplanos equivalentes, através da multiplicação de  $w$  e  $b$  por uma mesma constante. Desta forma, define-se o hiperplano canônico em relação ao conjunto  $T$  como aquele em que  $w$  e  $b$  são escalados de forma que os exemplos mais próximos ao hiperplano  $w \cdot x + b = 0$  satisfaçam a Equação 13 (LORENA; CARVALHO, 2007), (SOUZA, 2019 b), (BRUSAMARELLO et al., 2022), (NEGRI, 2013).

$$|w \cdot x_i + b| = 1 \quad (13)$$

Desta forma,

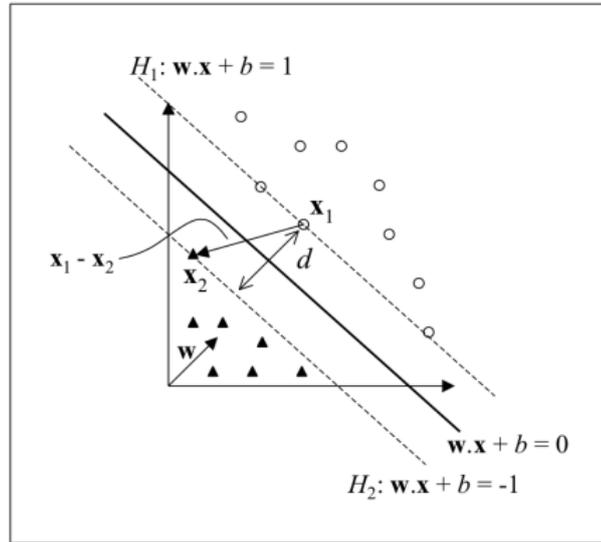
$$\begin{cases} w \cdot x_i + b \geq +1 & \text{se } Y_i = +1 \\ w \cdot x_i + b \leq -1 & \text{se } Y_i = -1 \end{cases} \quad (14)$$

$$y_i(w \cdot x_i + b) - 1 \geq 0, \forall (x_i, y_i) \in T \quad (15)$$

Seja  $x_1$  um ponto no hiperplano  $H_1 : w \cdot x + b = +1$  e  $x_2$  um ponto no hiperplano  $H_2 : w \cdot x + b = -1$ , conforme é mostrado na Figura 19 (BRUSAMARELLO et al., 2022), (LORENA; CARVALHO, 2007).

Projetando  $x_1$  e  $x_2$  na direção de  $w$ , perpendicular ao hiperplano separador  $w \cdot x + b = 0$ , é possível obter a distância entre os hiperplanos  $H_1$  e  $H_2$ . Essa projeção pode ser visualizada na Equação 16 (BRUSAMARELLO et al., 2022), (LORENA; CARVALHO, 2007).

Figura 19 – Cálculo da distância  $d$  entre os hiperplanos  $H_1$  e  $H_2$ .



Fonte: Lorena LORENA;Carvalho (2007)

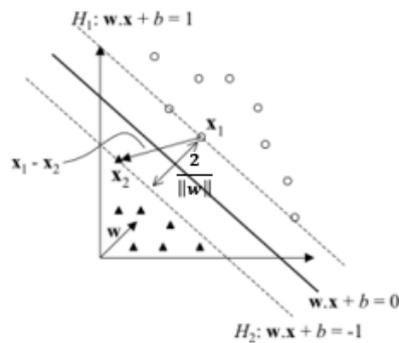
A margem de separação tem largura:

$$d = (x_1 - x_2) \left( \frac{w}{\|w\|} \cdot \frac{(x_1 - x_2)}{\|x_1 - x_2\|} \right) \quad (16)$$

Portanto  $w \cdot x_1 + b = +1$  e  $w \cdot x_2 + b = -1$ . Calculando a diferença entre essas equações tem-se  $w \cdot (x_1 - x_2) = 2$ . Ao substituir esse resultado na Equação (16) obtém-se a Equação 17

$$d = \frac{2(x_1 - x_2)}{\|w\| \|x_1 - x_2\|} \quad (17)$$

Figura 20 – Comprimento do vetor projetado.



Fonte: Adaptado de Negri (2013)

Com a necessidade de ter o comprimento do vetor projetado, toma-se a norma da Equação 16 obtendo  $\frac{2}{\|w\|}$ . Como pode ser observado na Figura 20 comprimento do vetor projetado (BRUSAMARELLO et al., 2022), (LORENA; CARVALHO, 2007), (CAMPBELL, 2001).

A distância  $d$  entre os hiperplanos  $H_1$  e  $H_2$ , e os vetores  $w$  e  $b$  foram escalados para não haver dados entre  $H_1$  e  $H_2$ . Sendo que,  $\frac{1}{\|w\|}$  é a distância mínima entre o hiperplano separador e os dados de treinamento. Essa distância é definida como a margem geométrica do classificador linear (CAMPBELL, 2001), (LORENA; CARVALHO, 2007).

Diante disso, a maximização da margem de separação dos dados em relação a  $w \cdot x + b = 0$  pode ser obtida pela minimização de  $\|w\|$ . Com isso, recorre-se ao problema de otimização (SCHÖLKOPF et al., 2002):

$$\text{Minimizar } \frac{1}{2} \|w\|^2 \quad (18)$$

sujeito a:

$$y_i(w \cdot x_i + b) - 1 \geq 0, \forall i = 1, \dots, n \quad (19)$$

Essas restrições são determinadas de maneira a certificar que jamais haja dados de treinamento entre as margens de separação das classes. Essa técnica é chamada SVM com margens rígidas em detrimento dessa restrição (MOSCA, 2004), (SOUZA, 2019 b), (GUIMARÃES, 2016), (LORENA; CARVALHO, 2007).

### 2.5.3 SVM com margens suaves

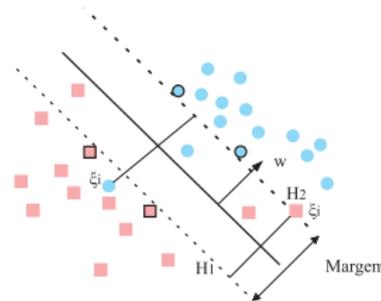
No mundo real, é difícil encontrar aplicações para dados linearmente separáveis. Esse fato acontece porque existem diversos fatores que causam ruídos e *outliers* que contaminam os dados, ou devido à própria natureza do problema, que pode ser não linear. Diante disso, são necessárias modificações no SVM clássico para tratar de casos que possam apresentar erros de treinamento. Essa alteração resulta em acrescentar uma “folga” nas equações, para que pontos que estejam dentro da margem superior ou inferior sejam admitidos. Essa nova técnica é denominada SVMs de margens suaves. Portanto, a introdução de variáveis de folga  $\xi_i$ , para todo  $i = 1, \dots, n$ , suavizando as restrições impostas ao problema de otimização, obedece a seguinte equacionamento (SCHÖLKOPF et al., 2002), (NEGRI, 2013), (LORENA; CARVALHO, 2007), (SOUZA, 2019 b):

$$\begin{cases} w \cdot x_i + b \geq +1 - \xi_i, & \forall y_i = +1 \\ w \cdot x_i + b \leq -1 + \xi_i, & \forall y_i = -1 \\ \xi_i \geq 0 \end{cases} \quad (20)$$

Ao aplicar esse procedimento ocorre a suavização das margens do classificador linear, possibilitando que alguns dados permaneçam entre os hiperplanos  $H_1$  e  $H_2$  e assim seja admita a ocorrência de alguns erros de classificação (LORENA; CARVALHO, 2007), (SOUZA, 2019 b).

A Figura 21 ilustra a classificação com SVM com margens suaves. Nela é possível observar alguns dados dentro da margem (GUIMARÃES, 2016).

Figura 21 – SVM com marges flexíveis.



Fonte

As restrições podem ser de duas formas. Na primeira, os dados são classificados de maneira correta, sendo  $0 \leq \xi_i \leq 1$ . Já a outra, acontece quando o dado é classificado de forma incorreta, ou seja,  $\xi_i > 1$  (LORENA; CARVALHO, 2007), (GUIMARÃES, 2016).

A margem para determinados casos pode assumir um valor muito elevado. Desta forma é comum atribuir um custo extra de erros à função objetivo, chamada de constante de regularização  $C$ , conforme pode ser visto na Equação 21 (LORENA; CARVALHO, 2007).

$$\underset{w, b, \xi}{\text{Minimizar}} \quad \frac{1}{2} \|w\|^2 + C(\sum_{i=1}^n \xi_i) \quad (21)$$

$C$  é um termo que impõe um peso à minimização da soma das folgas ou erros no conjunto de treinamento. Ele também pode ser interpretado como um parâmetro de penalização ao problema de otimização (FRIGIERI, 2016), (GUIMARÃES, 2016), (SOUZA, 2019 b).

Por exemplo, os valores altos de  $C$  tornam a função menos suave, permitindo menos amostras classificadas erroneamente e atribuem menor peso à margem do hiperplano (LORENA; CARVALHO, 2007), (NEGRI, 2013).

Por outro lado, a maioria dos problemas reais são não lineares, sendo que, uma transformação precisa ser aplicada ao conjunto de dados para o ajuste de uma função não linear (LORENA; CARVALHO, 2007).

#### 2.5.4 SVM não lineares

As SVMs lineares são eficientes na distribuição de conjuntos de dados linearmente separáveis ou possuem uma classificação aproximadamente linear, porém, a probabilidade dos dados sejam linearmente separáveis é mais baixa e para aplicar as SVMs rígidas e flexíveis é imprescindível a separação do conjunto de dados em forma linear (GUIMARÃES, 2016), (SOUZA, 2019 b).

Um método utilizado é manipular os dados de entrada, transformando-os na forma adequada para o processamento. Um conjunto de funções matemáticas transformam o conjunto dos dados de entrada de treinamento. Com isso, uma superfície de decisão não linear é capaz de se transformar em uma equação linear e em um número maior de espaços dimensionais. A essas funções é dado o nome Kernel (SOUZA, 2019 b), (GUIMARÃES, 2016).

Para aplicar em problemas não lineares, é necessário fazer uma redução para diversos problemas binários. Por exemplo, ao aplicar a função de kernel, a mesma transforma os dados não lineares no espaço original em um espaço de atributos de dimensão maior chamado de espaço de característica usando o mapeamento (SOUZA, 2019 b), (GUIMARÃES, 2016), (LORENA; CARVALHO, 2007).

Ao utilizar a Equação 22, o hiperplano não separa somente corretamente as classe, mas também, faz com que a margem seja máxima. (SINGLA et al., 2011).

$$f(x) = \text{sgn} \left( \sum_{i=1}^l \alpha_i^* y_i K(x, x_i) + b \right) \quad (22)$$

$\alpha_i^*$  é o operador Lagrange e  $K(x, x_i) = \varphi(x_i) \cdot \varphi(x)$  e a função Kernel.

A escolha do kernel e seus hiperparâmetros pode afetar o desempenho na classificação. A Tabela 3 apresenta as funções comuns do kernel: sigmoidal, polinomial e função base radial (RBF)(LORENA; CARVALHO, 2007),(NEGRI, 2013).

Tabela 3 – Funções Kernel mais comum.

Tipo de Kernel	Função K
Função base radial (RBF)	$K(x, x_i) = \exp(-\sigma^2 \cdot   x - x_i  ^2)$
Kernel polinomial:	$K(x, x_i) = (\delta(x \cdot x_i) + k)^d$
Kernel <i>sigmoid</i>	$K(x, x_i) = \tanh(\delta(x \cdot x_i) + k)$

Fonte: Wang *et. al* ( 2018)

A cada Kernel, estão associados hiperparâmetros, que são responsáveis por adicionar versatilidade ao modelo, possibilitando que alguns dados sejam classificados de forma incorreta(NEGRI, 2013).

Os mais comumente utilizados são os hiperparâmetros C e Gamma. O hiperparâmetro C controla a tolerância dos erros de classificação do modelo treinado. Aumentando o valor de C, podendo levar a overfitting e demora no tempo de treinamento por gerar fronteiras de decisão muito complexas. Valores baixos de C irão flexibilizar o treinamento, permitindo o surgimento de Soft Margin, ou melhor, fronteiras de decisão com erros. Podem resultar também em underfitting (BRUSAMARELLO et al., 2022).

O hiperparâmetro Gamma é utilizado somente no SVM não linear, através das funções de Kernel (especificamente o RBF, polinomial e sigmoide). Ele influencia na distância na qual as amostras serão consideradas para o cálculo da fronteira de decisão e, com isso, pode ser interpretado como uma maneira de flexibilizar o treinamento do modelo (BRUSAMARELLO et al., 2022). Valores de Gamma maiores fazem com que os pontos mais distantes da região de separação entre classes sejam desconsiderados, ocasionando em fronteiras de decisão mais restritas e complexas. Diminuindo os valores de Gamma, por outro lado, aumentam a influência dos pontos mais distantes e flexibilizam a região de separação. Isso permite que alguns erros de classificação, podendo ocasionar underfitting (BRUSAMARELLO et al., 2022).

Dentre esses 3 Kernels, o RBF vem se destacando na resolução de problemas reais. Além disso, kernel polinomial tem a necessidade de usar o hiperparâmetro Gamma ( $\gamma$ ) e o grau (d) fazendo com que aumente o desempenho e complexidade do classificador (LORENA; CARVALHO, 2007); (GUIMARÃES, 2016); (SOUZA, 2019 b); (BRUSAMARELLO et al., 2022); (PANG et al., 2011).

Por outro lado, o kernel sigmoide, a depender dos valores dos hiperparâmetros empregados, podem ter um comportamento parecido com RBF (BRUSAMARELLO et al., 2022), (PANG et al., 2011).

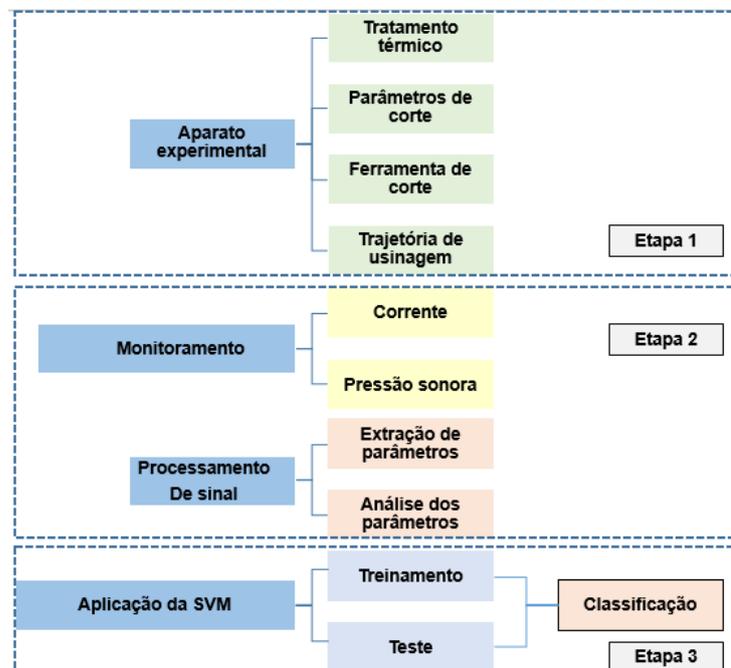
### 3 MATERIAIS E MÉTODOS

Neste tópico, será descrito o planejamento experimental, os materiais e os equipamentos para a realização desse experimentos com o intuito de adquirir o sinal da corrente do motor eixo-árvore e da pressão sonora. A fim de, verificar se existiu variação de dureza de cada peça e com o *datasets* aplicar SVM para classificar o material por nível de dureza.

#### 3.1 PLANEJAMENTO DOS EXPERIMENTOS

A metodologia utilizada para a realização dos experimentos foi constituída por três etapas, conforme é mostrado na Figura 22, a mesma foi dividida nas seguintes etapas:

Figura 22 – Metodologia proposta.



Fonte: Elaborada pela autora (2022).

Etapa 1: Preparação do experimento;

Etapa 2: Execução e análise do experimento;

Etapa 3: Treinamento e teste do SVM.

A Etapa 1 consiste na preparação do corpo de prova, determinação das condições de corte, bem como especificação da trajetória da ferramenta. Na segunda etapa, os microcontroladores foram preparados, consistindo da escrita de programas para a aquisição e tratamento dos sinais, transferência de sinais, extração de parâmetros e análise. Na etapa três, ocorreu aplicação da técnica SVM com o intuito de classificar o material. Além disso, os dados foram separados em treinamento, teste e validação. Cada etapa apresentada acima será detalhada nos tópicos abaixo.

### 3.2 CARACTERÍSTICAS DO COPO DE PROVA

O material empregado foi aço AISI 4340 o mesmo possui uma excelente propriedade mecânica devido a sua composição química. Na Tabela 4 encontra-se a composição química do aço AISI 4340 (OLIVEIRA, 2014); (BARROS et al., 2015).

Tabela 4 – Composição química do aço AISI 4340 por porcentagem em peso.

<b>C</b>	<b>Mn</b>	<b>Si</b>	<b>S</b>	<b>P</b>	<b>Cr</b>	<b>Mo</b>	<b>Ni</b>
0,4	0,65	0,21	0,012	0,015	1,05	0,3	1,36

Fonte: Barros *et al.* (2015)

Para aumentar resistência mecânica de cada corpo de prova foi realizado o tratamento térmico na empresa Tecnotempera. Porém, os 4 corpo de prova tinha uma dureza inicial variando entre 17 HRC a 20 HRC antes do tratamento térmico para atender a proposta do trabalho, o tratamento térmico realizado foi têmpera em seguida o revenimento. As durezas especificadas para cada um dos corpos de prova foram 30HRC, 35HRC, 40HRC e 45HRC e a atingida para cada corpo de prova pode ser observado na Tabela 5.

Tabela 5 – Propriedades mecânicas típicas de um aço AISI/SAE 4340.

<b>Corpo de prova</b>	<b>Dureza HRC</b>
1	32
2	36
3	42
4	45

Fonte: Elaborado pela autora (2022)

### 3.3 APARATO EXPERIMENTAL

Os experimentos foram realizados no Laboratório Dinâmica da Usinagem na UDESC de Joinville no centro de usinagem vertical Romi D600. A máquina-ferramenta possui rotação máxima do fuso de 10.000 rpm e potência de 15KW e utilizou um cone do eixo árvore ISO BT40. Além disso, o inserto utilizado foi de metal duro do fabricante Sandvik Coromant com especificação R390-11T308M-PM1010.

O parâmetro de corte utilizado para realizar os ensaios foram: velocidade de corte de 200 m/min, avanço por dente de 0,1 mm/dente, a profundidade do corte axial  $a_p$  2mm e profundidade radial  $a_e$  10mm. Para o melhor aproveitamento do material dos corpos de prova, decidiu-se usar somente 25% da circunferência o mesmo possui um diâmetro de 114 mm e o comprimento de 50 mm. A trajetória da ferramenta foi circular para manter  $a_e$  constante. O sentido de corte foi

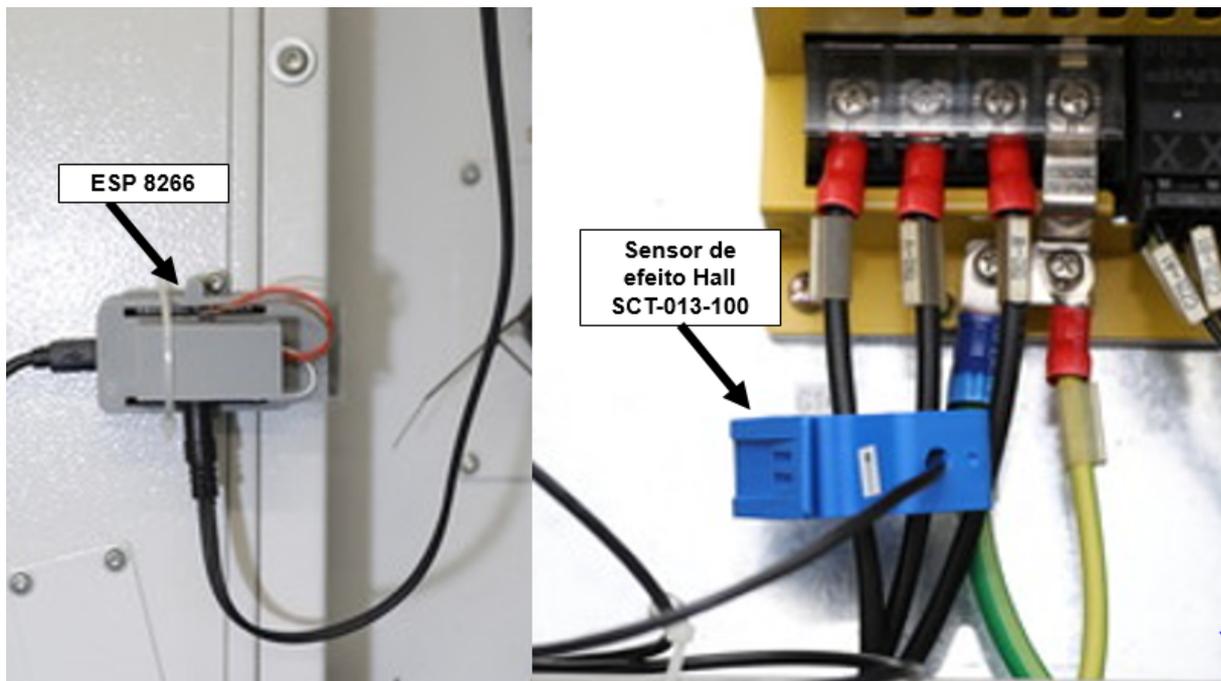
concordante, iniciou com espessura máxima de cavaco até essa espessura chegar ao seu valor mínimo.

### 3.4 SISTEMA DE AQUISIÇÃO DE SINAIS

A aquisição dos sinais monitorados foram utilizados microcontroladores de placa única, tais como: ESP8266 e Raspberry Pi Zero. A placa ESP8266 NodeMCU DEVKIT 1.0. NodeMCU é uma plataforma de baixo custo e *open-source*. Essa placa permite que o microcontrolador se conecte a uma rede sem fio com portas de entrada e saída onde é possível ocorrer o sensoriamento (PEIXOTO, 2021). A placa tem processador de 32-bit RISC Tensilica Xtensa LX106 a uma frequência de 80Mhz a 160Mhz, o que é o suficiente para adquirir os sinais de corrente do motor do eixo-árvore, processar e enviar os resultados. A placa ainda tem armazenamento 4 MBytes.

Além disso, um sensor de efeito Hall SCT-013-100 conectado a placa ESP8266 foi utilizado para a medição da corrente. O sensor foi montado no painel elétrico traseiro da máquina e a placa ESP8266 acoplada na estrutura como pode ser visualizada na Figura 23 o sensor e a placa montados na máquina- ferramenta.

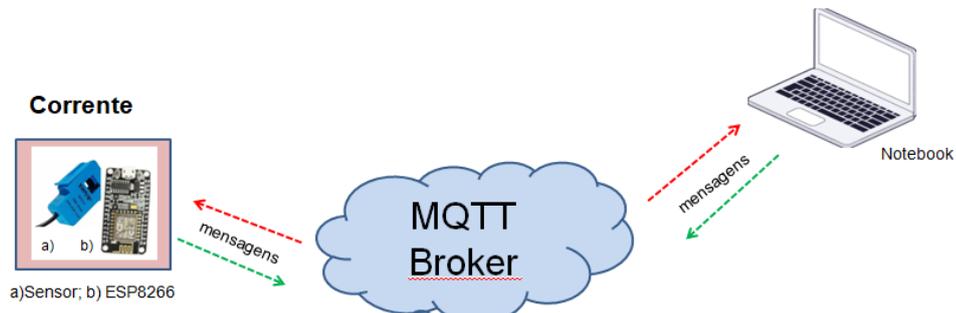
Figura 23 – Arranjo da instalação para aquisição do sinal da corrente.



Fonte: Elaborada pela autora (2022)

O sinal foi adquirido no domínio do tempo utilizando a biblioteca EmonLib (*Energy Monitoring Library*). Foi programado utilizando a linguagem C no arduino IDE sendo, uma montagem análoga ao experimento apresentado Souza *et. al* (2017). O sinal de corrente adquirido pela placa é processando, foi calculado o valor de RMS a cada ciclo e enviado em tempo real para o PC, utilizando o protocolo de comunicação MQTT (*MQ Telemetry Transport*) como é exemplificado na Figura 24.

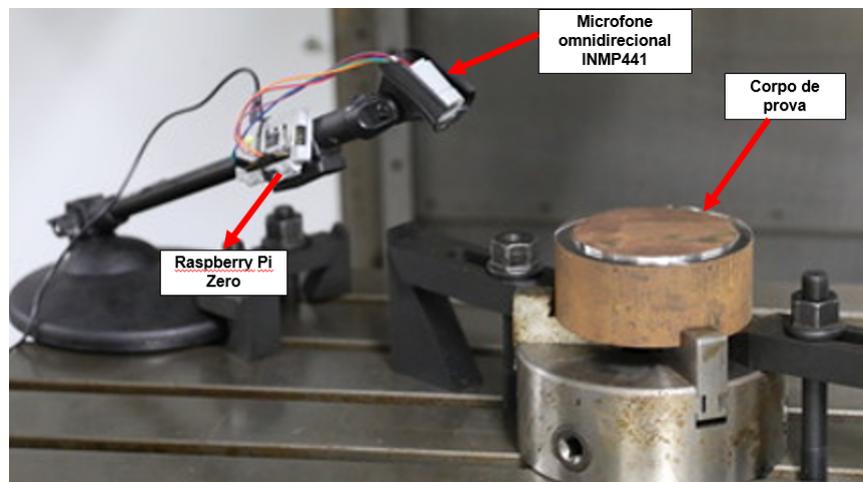
Figura 24 – Aquisição do sinal da corrente.



Fonte: Elaborada pela autora (2022).

Os sinais da pressão sonora adquirido foi através da placa Raspberry Pi Zero, pois tem maior capacidade de processamento e pelo fato de ser possível armazenar o sinal em cartão de 32 GB SD instalado na própria placa. Além disso, empregou um microfone omnidirecional modelo INMP441 conectado diretamente à placa Raspberry Pi Zero e a frequência de amostragem foi de 44,1 KHz. Na Figura 25 temos o arranjo da instalação do microfone omnidirecional modelo INMP441 conectado à placa Raspberry Pi Zero acoplado a mesa da fresadora por meio do suporte para microfone.

Figura 25 – Arranjo da instalação para aquisição do sinal da pressão sonora.



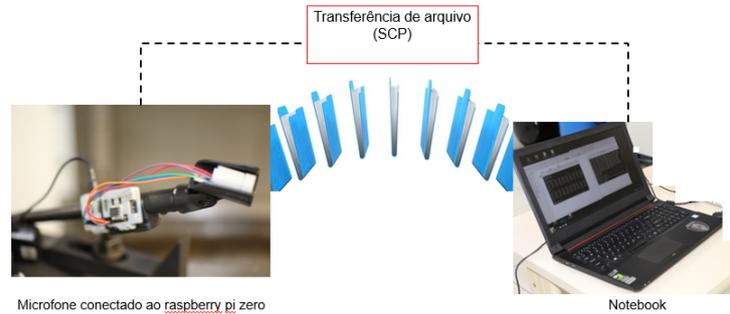
Fonte: Elaborada pela autora (2022).

Decidiu-se utilizar o sinal de pressão sonora sem conversão. A justificativa é baseada no fato de que nem a calibração do sistema, nem convertido para a escala logarítmica conforme apresentado por Coulby *et al.* (2021), contribuiriam com a melhora na qualidade do monitoramento do processo.

Durante o experimento, os dados da pressão sonora foram gravados em um cartão SD de 32 GB na própria placa. Após cada experimentos esses dados eram enviados para o computador via WiFi, conforme mostra a Figura 26, foi utilizado o comando SCP (*Secure Copy Protocol*) para transferência de arquivo de forma remota. SCP é protocolo de rede para transferências de

arquivos entre *host*.

Figura 26 – Aquisição dos sinais de pressão sonora.



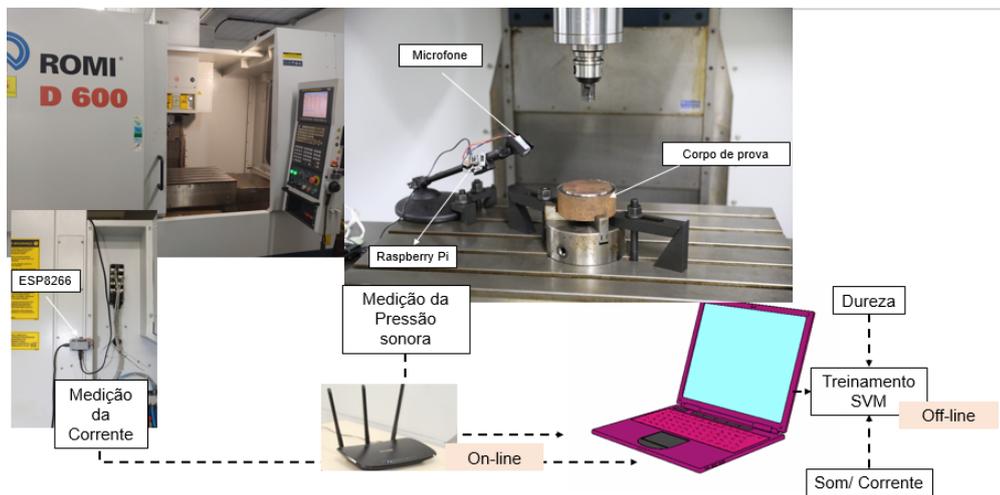
Fonte: Elaborada pela autora (2022)

Os sinais de som adquiridos para todos os ciclos de corte foram nomeados com: data e hora, pois esse arquivo servirá como reconhecimento de dados para o algoritmo. Essa forma de comunicação foi implementada para evitar perda de dados. Após adquiridos os dados, o mesmo serão tratados com o auxílio do Python.

### 3.5 PROCEDIMENTO APLICADO PARA ANÁLISE DOS DADOS

A Figura 27 apresenta um esquema exemplificando a realização dos ensaios para a aquisição dos sinais monitorados, treinamento e teste da SVM.

Figura 27 – Aquisição dos sinais para treinamento SVM



Fonte: Elaborada pela autora (2022)

As condições de corte foram as mesmas para os quatro corpos de prova e o tempo de aquisição do sinal de 40 segundos. A região utilizada para análise, ocorreu onde a ferramenta se encontrava em regime (corte em cheio). Nesse intervalo, oito janelas de dados dos sinais foram escolhidas.

Dos oito pontos amostrados, a primeira amostra é utilizada para efeito de comparação da influência da dureza na característica do sinal.

Após aquisição e análise dos dados da corrente e da pressão sonora foi feito o treinamento da SVM de forma *off-line*. Os dados coletados e pré-processados, em seguida, foram extraídas as características dos sinais que melhor se correlacionar com a variação da dureza. Dos dados, 78% foi utilizado para o treinamento e 22% teste e validação.

A categorização dos dados para auxiliar no treinamento foi definida como padrão conforme a Tabela 6 classificando por nível de dureza (A, B, C e D). Para implementação do SVM foi utilizando o Orange Canvas com a linguagem em Python.

Tabela 6 – classificação por nível de dureza

<b>Nível</b>	<b>Faixa de dureza (HRC)</b>
A	32
B	36
C	42
D	45

Fonte: Elaborada pela autora (2022).

Para a implementação do SVM foi necessário definir a função kernel mais adequado (polinomial, RBF e sigmóide) e seus hiperparâmetro. Em relação à aplicação da função kernel avaliou o desempenho do classificador através da matriz de confusão e as métricas aplicadas foram precisão e acurácia. Além disso, analisou a quantidade de atributos com melhor desempenho tais como, RMS da corrente combinado valor de pico, RMS, fator de crista e curtose da pressão sonora com 5 atributos, 4 atributos (RMS da corrente, valor de pico, RMS e curtose da pressão sonora), 3 atributos (RMS da corrente, valor de pico, e curtose da pressão sonora) e 2 atributos (RMS da corrente e curtose da pressão sonora).

O método adotado para avaliar o desempenho do classificador SVM sucedeu através da matriz de confusão e as métricas aplicadas, precisão e acurácia. Por exemplo, na Figura 28 nota-se uma matriz de confusão, os elementos da diagonal principal representam os dados classificados corretamente e todos os elementos fora da diagonal principal que tiveram previsões incorretas. Portanto, é possível verificar o percentual e a quantidade de previsões que foram corretas e incorretas. Além disso, para calcular a acurácia, obtido o valor da soma verdadeiro positivo mais verdadeiro negativo dividido pela quantidade de itens do conjunto de dados e com isso é possível observar o quão é exato e preciso ao aplicar o algoritmo.

Figura 28 – Matriz de Confusão para classificação multiclasse.

		Classe real			
		Classe 1	Classe 2	Classe 3	Classe 4
Classe prevista	Classe 1	Classificação Correta	Classificação incorreta	Classificação incorreta	Classificação incorreta
	Classe 2	Classificação incorreta	Classificação Correta	Classificação incorreta	Classificação incorreta
	Classe 3	Classificação incorreta	Classificação incorreta	Classificação Correta	Classificação incorreta
	Classe 4	Classificação incorreta	Classificação incorreta	Classificação incorreta	Classificação Correta

Fonte: Elaborada pela autora (2022)

A Tabela 7 apresenta o padrão de organização adotado da matriz de confusão em termos do número de dados corretos e incorretos classificados, da precisão e da acurácia, utilizado na avaliação da função Kernel e do conjunto de parâmetros para treinar a SVM.

Tabela 7 – Modelo da matriz de confusão do número de amostra, precisão e da acurácia.

		Classe verdadeira			
		A	B	C	D
Condição prevista	A	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia
	B	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia
	C	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia
	D	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia	Amostra Precisão Acurácia

Fonte: Elaborada pela autora (2022)

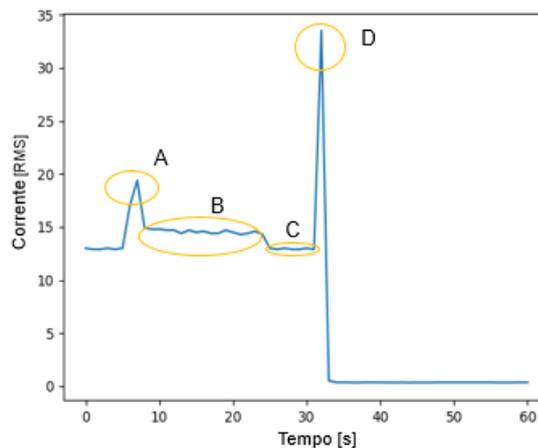
## 4 RESULTADOS E DISCUSSÕES

Neste capítulo são analisados os sinais adquiridos de corrente elétrica do motor do eixo-árvore e da pressão sonora, variando a dureza do material da peça usinada. São investigados também quais parâmetros extraídos de ambos sinais, bem como a função Kernel da SVM, que melhor se adequam para o monitoramento da variação de dureza da peça. Este capítulo está dividido nos seguintes tópicos: corrente do motor do eixo-árvore, pressão sonora e máquina de vetor de suporte.

### 4.1 CORRENTE DO MOTOR DO EIXO-ÁRVORE

A Figura 29 apresenta o comportamento da corrente RMS do motor do eixo-árvore em função do tempo. Esse resultado é apresentado para o aço AISI 4340 com a dureza de 32 HRC. A mesma tendência é observada para as outras durezas de material da peça usinada. Esse é um comportamento observado por outros autores, com picos de corrente nas regiões de entrada e saída da ferramenta da região de corte e valores de corrente RMS proporcionais à área média da seção transversal dos insertos da ferramenta que estão engajados (SOUSA et al., 2017).

Figura 29 – Sinal da corrente em função do tempo (A-entrada da ferramenta, B- regime de corte, C- saída da ferramenta da peça, D- desligamento do motor).



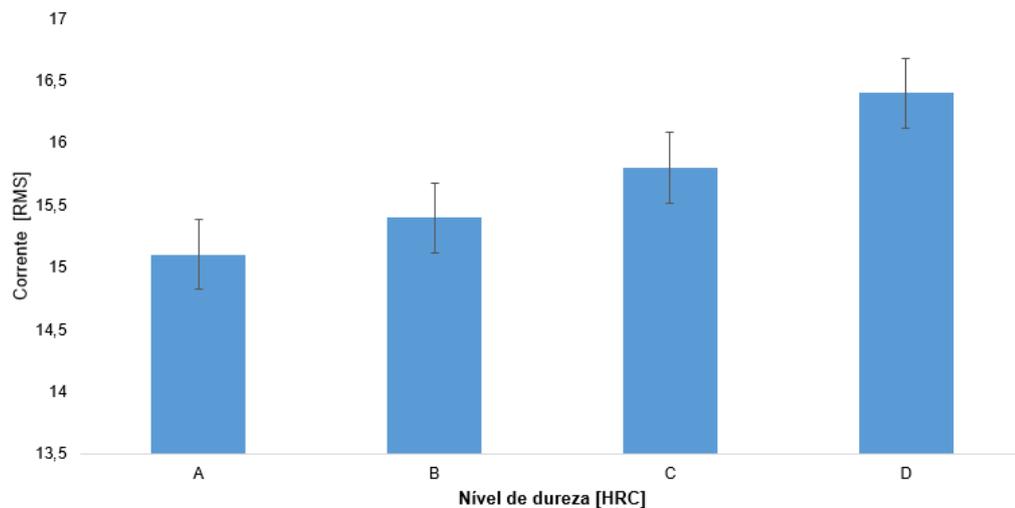
Fonte: Elaborada pela autora (2022)

Da Figura 29 é possível ver 4 regiões da curva da corrente:

- **Região A:** corresponde a entrada da ferramenta no corpo de prova;
- **Região B:** corpo de prova está sendo usinado;
- **Região C:** saída do corte e usinagem em vazio;
- **Região D:** ocorre desligamento do motor.

Desses resultados, cabe salientar que os picos de corrente não serão utilizados como parâmetro para o monitoramento da variação da dureza porque sofrem influência do momento da aquisição. Isto é, não se tem o controle da quantidade de pontos antes e depois do pico. Como o cálculo do valor do RMS é integrado ao longo do tempo, este depende do instante inicial, o que pode incorrer em erros. O mesmo procedimento é adotado para o pico de corrente na saída da ferramenta. Com isso, a região de análise dos gráficos para os valores de dureza diferentes é a B da Figura 29.

Figura 30 – Sinal de corrente RMS do primeiro ponto para diferentes durezas do material da peça A-32HRC, B-36HRC, C-42HRC e D-45HRC.



Fonte: Elaborada pela autora (2022)

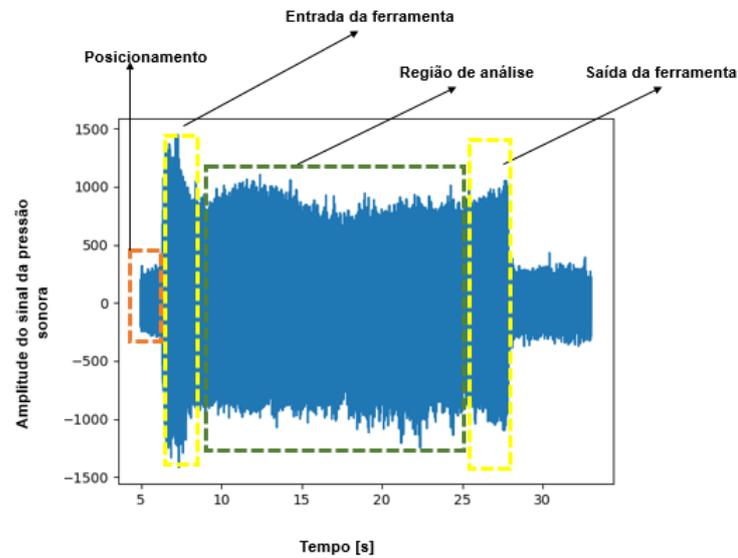
O valor médio da corrente RMS na região B é então analisado para diferentes durezas como pode ser observado na Figura 30, existe uma clara tendência de aumento da corrente do motor do eixo-árvore com o aumento da dureza do material da peça de 32HRC (corpo de prova A) para 45HRC (corpo de prova D). Essa variação corresponde ao conceito apresentado na seção 2.3.1 que relaciona a corrente do motor do eixo-árvore com  $K_{c1.1}$  esse, que por sua vez depende da propriedade do material.

Um ponto que deve ser considerando é que a variação da corrente RMS pode não ser sensível o bastante com a variação da dureza ou até mesmo sofrer influência de ruídos elétricos e magnéticos. Por isso, outra grandeza deve ser analisada, como é a pressão sonora, sendo facilmente adquirida e de fácil implementação no espaço da máquina-ferramenta.

## 4.2 PRESSÃO SONORA

Sinais de pressão sonora foram adquiridos utilizando um microfone INMP4122 ligado a um raspberry pi zero. Conforme apresentado na seção Sistema de aquisição de sinais, o sensor INMP4122 ligado ao raspberry pi zero necessitariam ser calibrados para apresentar os valores de saída em unidade de pressão sonora. Entretanto, esse procedimento não foi necessário porque para realizar a classificação o importante é a variação do sinal em relação a um sinal de referência.

Figura 31 – Sinal da pressão sonora no domínio do tempo para a dureza 17 HRC.



Fonte: Elaborada pela autora (2022)

A Figura 31 apresenta um gráfico típico do sinal da pressão sonora em função do tempo. A primeira região é caracterizada pela rotação da ferramenta, sem a remoção de material da peça (corte em vazio). Logo em seguida é observado um aumento rápido do sinal sonoro devido à entrada da ferramenta na região de corte. Em relação ao corpo de prova apresentado na seção Materiais e Métodos, a ferramenta penetra na peça na direção radial, aumentando progressivamente  $a_e$ , enquanto  $a_p$  é mantido constante.

A terceira região do sinal (região de análise) é obtida quando a ferramenta percorre o caminho do arco de circunferência de raio R, mantendo  $a_e$  e  $a_p$  constantes, percorrendo 1/4 de circunferência. Nesse trajetória os dados da pressão sonora são adquiridos. Logo em seguida a ferramenta sai do corte se afastando da peça na direção radial (saída da ferramenta). A região do gráfico escolhida para análise segue o mesmo princípio de Miko e Nowakowski (2012).

Os parâmetros analisados foram estatísticos, no domínio do tempo, por ser usado com sucesso para o monitoramento de condições de máquinas elétricas (SAUCEDO-DORANTES et al., 2018).

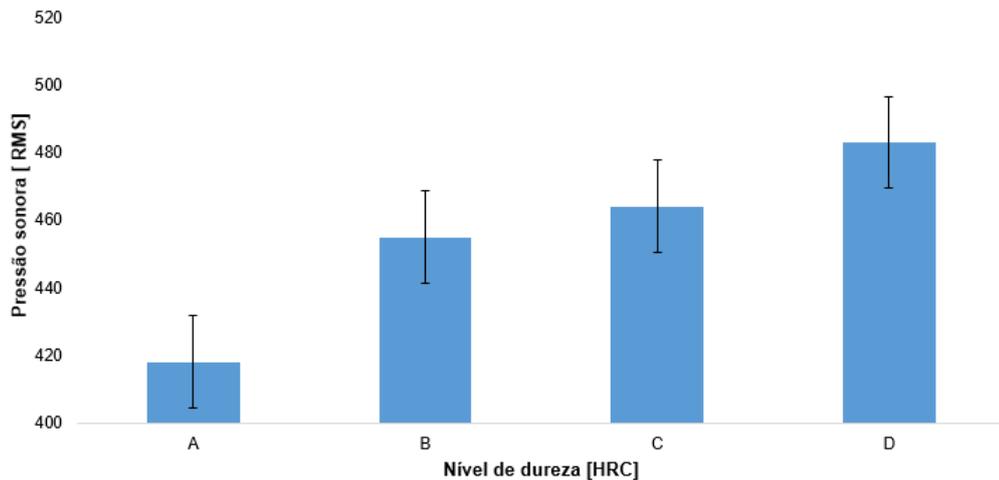
Isso se deve ao fato da capacidade de fornecer informações sobre tendências gerais e sua simplicidade de implementação, com baixo custo computacional e necessitando de pouca memória para calculá-los (HUERTA-ROSALES et al., 2021).

Para cada janelamento foram calculados os parâmetros estatísticos no domínio do tempo, tal como, RMS, valor de pico, fator de crista e curtose, baseados nas equações abordada na seção 2.4.2.

A influência da variação da dureza da peça no valor de RMS do sinal sonoro pode ser visto na Figura 32.

Como já mencionado na seção 2.4.2, o RMS indica o nível de energia do sinal. Deste modo, percebe-se que, a medida que a dureza aumenta, aumenta o valor de RMS. Pode-se com isso concluir que o sistema vibra com mais intensidade a medida que o material da peça se torna mais duro. Outro fator a observar é que a relação entre o RMS do sinal e a dureza do material.

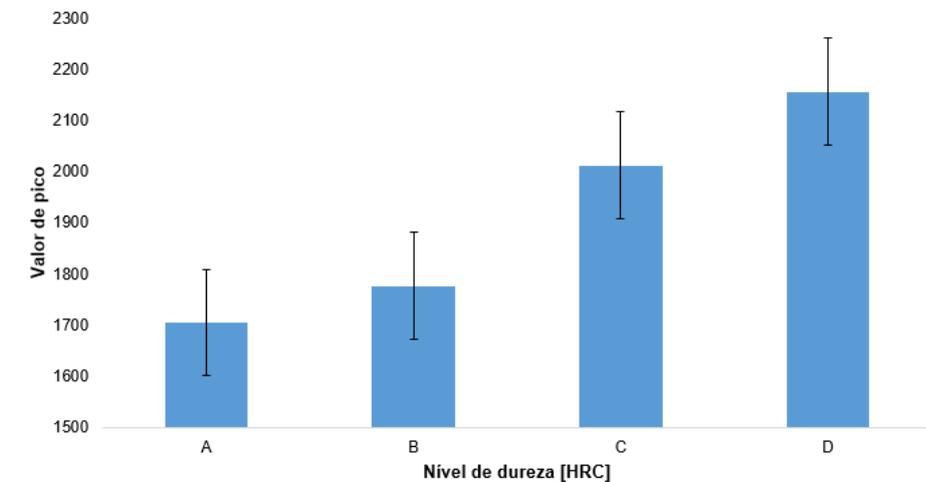
Figura 32 – RMS do sinal sonoro.



Fonte: Elaborado pela autora (2022)

Ao observar a Figura 33, nota-se também que com aumento da dureza do material da peça, o valor de pico do sinal sonoro aumenta. O valor de pico, como discutido na seção 2.4.2, está relacionado com o valor máximo do sinal. Com isso, quanto mais duro for o material da peça, maior será o impacto da ferramenta e desse modo, os picos do sinal. O sinal também apresenta uma tendência de aumento do valor do pico com o aumento da dureza do material da peça.

Figura 33 – Valor de pico do sinal sonoro.

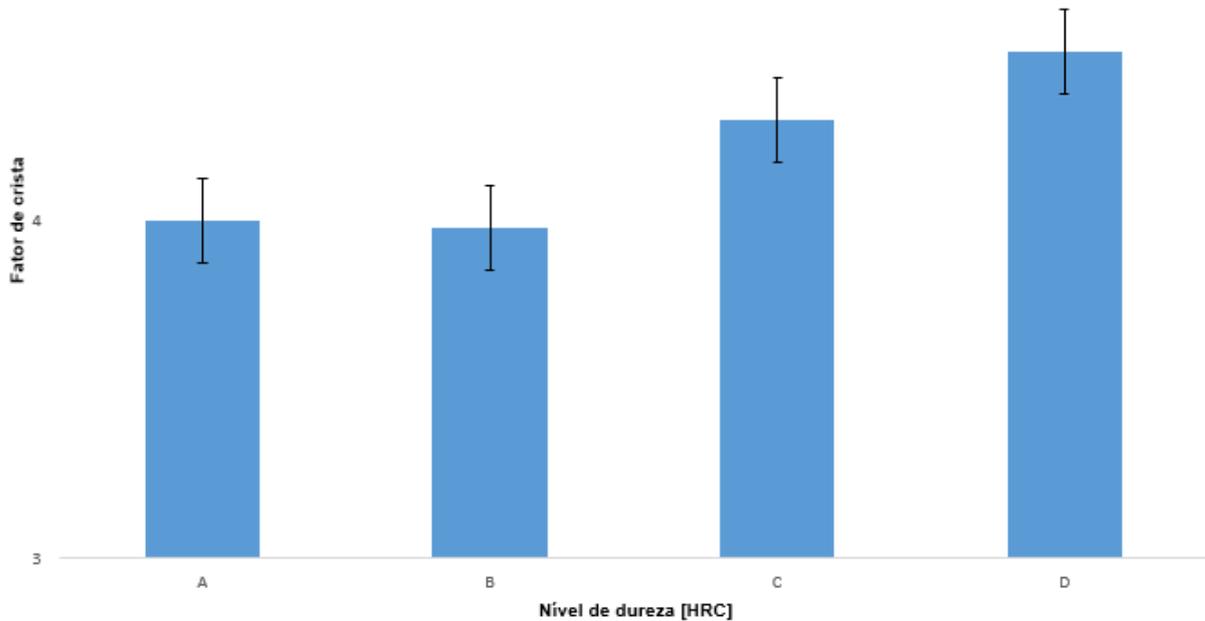


Fonte: Elaborada pela autora (2022)

O fator de crista indica quão extremos são os picos em uma onda. Observando os

resultados em função da dureza, pode-se observar uma leve tendência de aumento. Exceção da dureza de 36 HRC (nível B), com valor menor do que para a dureza de 32 HRC (nível A), Figura 34.

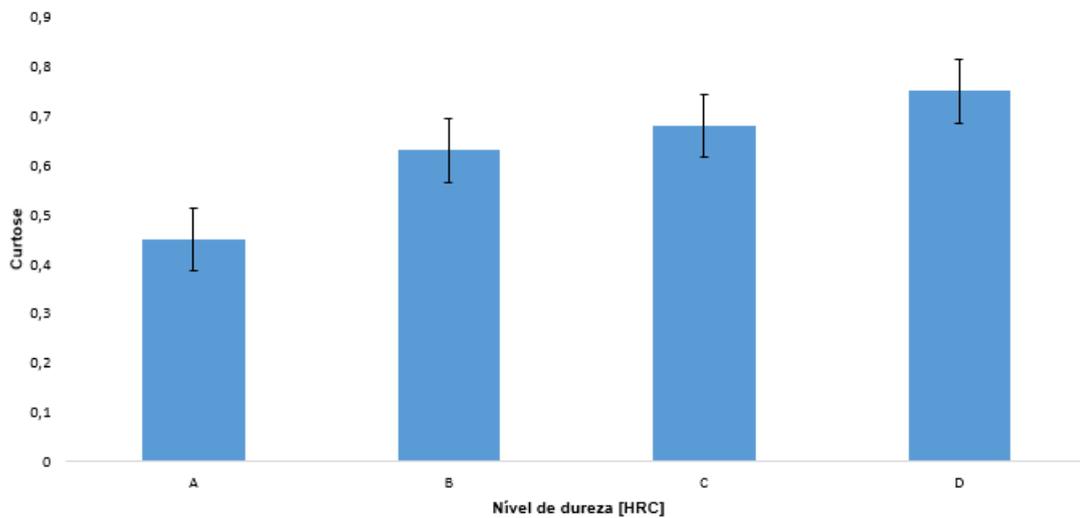
Figura 34 – Fator de Crista do sinal sonoro.



Fonte: Elaborada pela autora (2022)

Já com relação à curtose do sinal sonoro é observado, de novo, uma tendência de aumento, com o aumento da dureza do material da peça, como é constatado na Figura 35.

Figura 35 – Curtose.



Fonte: Elaborada pela autora (2022)

O coeficiente de correlação foi calculado para os parâmetros extraídos do sinal sonoro

e são apresentados na Tabela 8. Percebe-se que existe uma correlação para cada parâmetro extraídos analisado com a variação da dureza do material. Portanto, foi possível avaliar que quanto maior dureza do material maior a pressão sonora.

Tabela 8 – Correlação dos parâmetros estatísticos com o nível de dureza e sua significância para análise.

<b>Parâmetro</b>	<b>Coef. de correlação</b>	<b>Significativo</b>
Pico	0.99	Sim
RMS do som	0.95	Sim
Fator de Crista	0.80	Sim
Curtose	0.94	Sim
RMS da corrente	0.97	Sim

Fonte: Elaborada pela autora (2022).

### 4.3 APLICAÇÃO DA SVM

Os valores dos parâmetros calculados da corrente e pressão sonora estão numa faixa ampla de valores, o que pode causar problemas para o treinamento da SVM. Por isso, foram normalizados para valores entre 0 e 1. Para verificar o melhor desempenho da SVM, optou-se por verificar um classificador com 5, 4, 3 e 2 atributos para treinamento. Assim, o parâmetro RMS da corrente foi combinado com valor de pico, RMS, fator de crista e curtose do sinal de pressão sonora. Além disso, foi avaliado a influência da função Kernel.

#### 4.3.1 Influência do Kernel

##### 4.3.1.1 Kernel RBF

O primeiro treinamento foi realizado considerando o total dos cinco parâmetros extraídos dos sinais, para treinar a SVM (RMS da corrente, valor de pico, RMS, fator de crista e curtose da pressão sonora). Foi empregando o Kernel RBF com os hiperparâmetro  $C = 100$  e o  $\gamma = 0,01$ . O classificador obteve uma precisão de 96% e uma acurácia de 96%, como é possível observar na Tabela9. Nota-se que o classificador obteve um erros ao categorizar o nível de dureza entre B e C, os dados com característica de B foram categorizados como C. Portanto, houve maior dificuldade em distinguir entre os níveis B e C pois, as características foram confundidas. Isso pode ter ocorrido devido à distribuição dos dados.

Tabela 9 – Matriz de confusão do modelo com cinco atributos aplicando a função kernel RBF.

		Classe verdadeira			
		A	B	C	D
Condição prevista	A	6 100% 100%	0	0	0
	B	0	5 100% 83,3%	1 14,3 16,7%	0
	C	0	0	6 85,7% 100%	0
	D	0	0	0	5 100% 100%

Fonte: Elaborada pela autora (2022)

#### 4.3.1.2 Kernel Sigmoid

Empregando agora função Kernel *sigmoid* utilizando com os hiperparâmetro  $C = 1$  e  $\gamma = 0,01$  o classificador treinado obteve uma precisão de 91,6% uma acurácia de 87%, como pode ser notado na Tabela 10.

Tabela 10 – Matriz de confusão do modelo com cinco atributos aplicando a função kernel sigmoid.

		Classe verdadeira			
		A	B	C	D
Condição prevista	A	6 100% 100%	0	0	0
	B	0	6 66,7% 100%	0	0
	C	0	3 33,3 50%	3 100% 50%	0
	D	0	0	0	5 100% 100%

Fonte: Elaborada pela autora (2022)

Ainda sobre a Tabela 10 percebe-se que o classificador obteve 3 erros ao categorizar o nível de dureza entre B e C, 3 amostras de C foram reconhecidas como B. Portanto, existe uma maior dificuldade em distinguir entre os níveis B e C. Isso pode ter ocorrido pois, foi empregado kernel *sigmoid*, portanto, existiu uma diminuição na precisão e na acurácia tendo maior erro quando comparado RBF (Tabela 9) com os cinco parâmetros estatísticos.

#### 4.3.1.3 Kernel Polinomial

Ao utilizar RMS da corrente e valor de pico, RMS, fator de crista e curtose da pressão sonora aplicando a função kernel polinomial com os hiperparâmetro  $C = 1$ ; o  $\gamma = 0,01$  e  $degree = 3$  o classificador treinado resultou em uma precisão de 87,5% (Tabela 11). Na Tabela 11 os dados classificados corretamente na diagonal principal e uma acurácia de 88%.

Tabela 11 – Matriz de confusão com os cinco parâmetros estatísticos no domínio do tempo aplicando a função kernel polinomial.

		Classe verdadeira			
		A	B	C	D
Condição prevista	A	6 100% 100%	0	0	0
	B	0	5 66,7% 100%	1 16,7 0	0
	C	0	3 33,3 50%	3 83,3% 50%	0
	D	0	0	0	5 100% 100%

Fonte: Elaborada pela autora (2022)

Porém, ao aplicar a função kernel polinomial o classificador teve dificuldade em tentar categorizadas entre os níveis de dureza B e C sendo que das 6 amostras de C, 3 foram categorizar como B e uma de B classificada como C.

Desta forma, ao analisar a função kernel aplicando cinco atributos, o que teve melhor desempenho na classificação das classes foi a RBF.

#### 4.3.2 Influência dos Parâmetros Extraídos

Nessa seção é investigado se a diminuição dos parâmetros estatísticos extraídos da pressão sonora para treinar a SVM tem alguma influência no classificador. Para isso foi utilizado o Kernel que melhor desempenho teve na seção anterior, o RBF, com os hiperparâmetro  $C = 100$  e o  $\gamma = 0,01$ .

- $RMS_{corr}, Curt_{som}, VP_{som}, RMS_{som}$

Os parâmetros escolhidos para treinar SVM foi a  $RMS_{corr}$ , curtose ( $Curt_{som}$ ), o valor de pico ( $VP_{som}$ ) e RMS do som  $RMS_{som}$ . A Tabela 12 apresenta a matriz confusão para o classificador treinado.

O classificador obteve 2 erros ao categorizadas o nível de dureza ente A e B sendo que 1 amostra com característica de A foi reconhecido como B e 1 de B foi classificado como A.

Tabela 12 – Matriz de confusão com quatro atributos aplicando a função kernel RBF.

		Classe verdadeira			
		A	B	C	D
Condição prevista	A	5 83,3% 83,3%	1 14,3% 16,7%	0	0
	B	1 16,7% 16,7%	5 71,4% 83,3%	0	0
	C	0	1 14,3% 16,7%	5 100% 83,3%	0
	D	0	0	0	5 100% 100%

Fonte: Elaborada pela autora (2022)

Além disso, das 6 amostras de C uma foi categorizada como B e das 5 amostras de D todas foram classificadas corretamente, obtendo uma acurácia de 87% (Tabela 12). Portanto, houve dificuldade em distinguir o nível A, B e C ao aplicar 4 parâmetros estatísticos resultado em uma menor precisão (89%) e menor acurácia quando comparado com cinco atributos aplicando a função kernel RBF.

- $RMS_{corr}$ ,  $Curt_{som}$ ,  $RMS_{som}$

Agora, o valor de pico  $VP_{som}$  é eliminado do treinamento, restando somente a curtose e o RMS do sinal de pressão sonora com o RMS da corrente do motor do eixo-árvore. Na Tabela 13, nota-se a matriz confusão para o classificador treinado com os 3 atributos são obtidos 4 erros ao categorizar por nível de dureza.

Tabela 13 – Matriz de confusão para o modelo com três atributos aplicando a função kernel RBF.

		Classe verdadeira			
		A	B	C	D
Condição prevista	A	5 83,3% 83,3%	1 12,5% 16,7%	0	0
	B	1 16,7% 16,7%	5 62,5% 83,3%	0	0
	C	0	2 25% 33,3%	4 100% 66,7%	0
	D	0	0	0	5 100% 100%

Sendo que uma das amostras de A foi classificada como B, uma de B categorizados como A e das 6 amostras de C 4 foram classificadas corretamente e duas de C classificadas como nível de dureza de B. Portanto, houve dificuldade em distinguir o nível A, B e C. Com isso, a precisão obtida foi de cerca de 87% (Tabela 13) e a acurácia de cerca de 84% (Tabela 13). O baixo rendimento da precisão e da acurácia pode ter ocorrido devido à escolha dos parâmetros estatísticos ou a quantidade de atributos.

- $RMS_{corr}, Curt_{som}$

A Tabela 14 apresenta a matriz de confusão empregando RMS da corrente e curtose da pressão sonora. É possível observar que uma precisão de 81% obtendo 5 erros. Sendo que, uma amostra de A foi reconhecida como B, das duas amostras de B uma foi classificada como A e a outra como C e duas amostras de C, foram categorizadas como B chegando a uma acurácia de 80% (Tabela 14).

Tabela 14 – Matriz de confusão para o modelo com dois atributos aplicando a função kernel RBF.

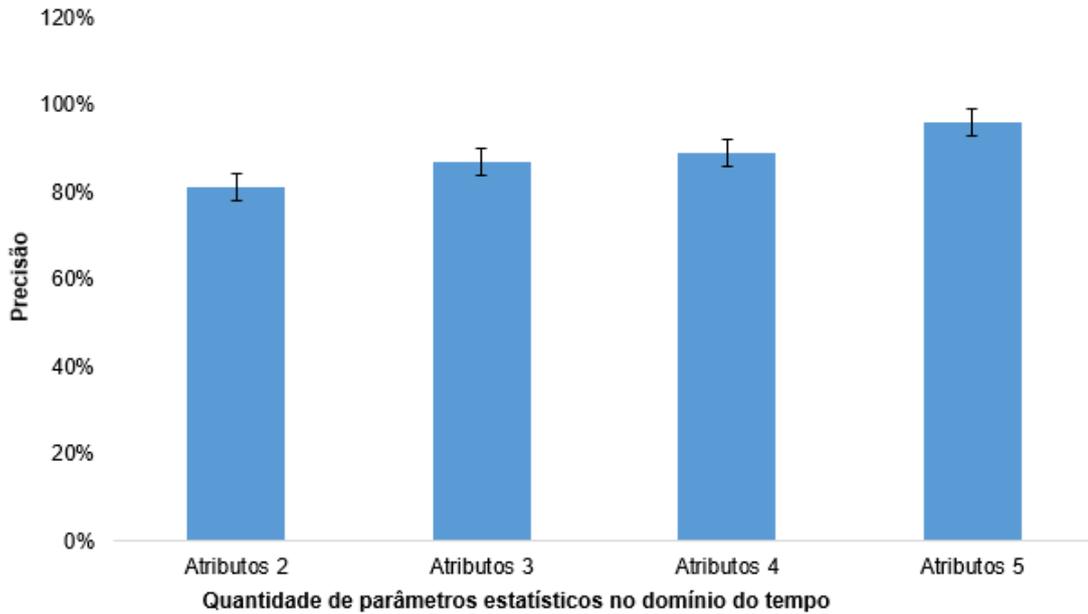
		Classe verdadeira			
		A	B	C	D
Condição prevista	A	5 83,3% 83,3%	1 14,3% 16,7%	0	0
	B	1 16,7% 16,7%	4 57,1% 66,7%	1 20% 16,7%	0
	C	0	2 28,6% 33,3%	4 80% 66,7%	0
	D	0	0	0	5 100% 100%

Fonte: Elaborada pela autora (2022)

#### 4.3.3 Comparação da influência dos parâmetros extraídos

A Figura 36 apresenta a precisão em relação à quantidade de parâmetros estatísticos no domínio do tempo com o tipo da função kernel aplicada. Nota-se que quanto maior a quantidade de atributos maior o impacto na classificação. com cinco atributos aplicando a função kernel RBF teve o melhor resultado quando comparado com a quantidade de atributos, chegando a obter 96% de precisão. Além disso, quando se aplicou 4 atributos o classificar obteve 88% de precisão e por fim com 2 atributos 81% de precisão. Portanto, fica evidente que a quantidade de atributos influencia na precisão.

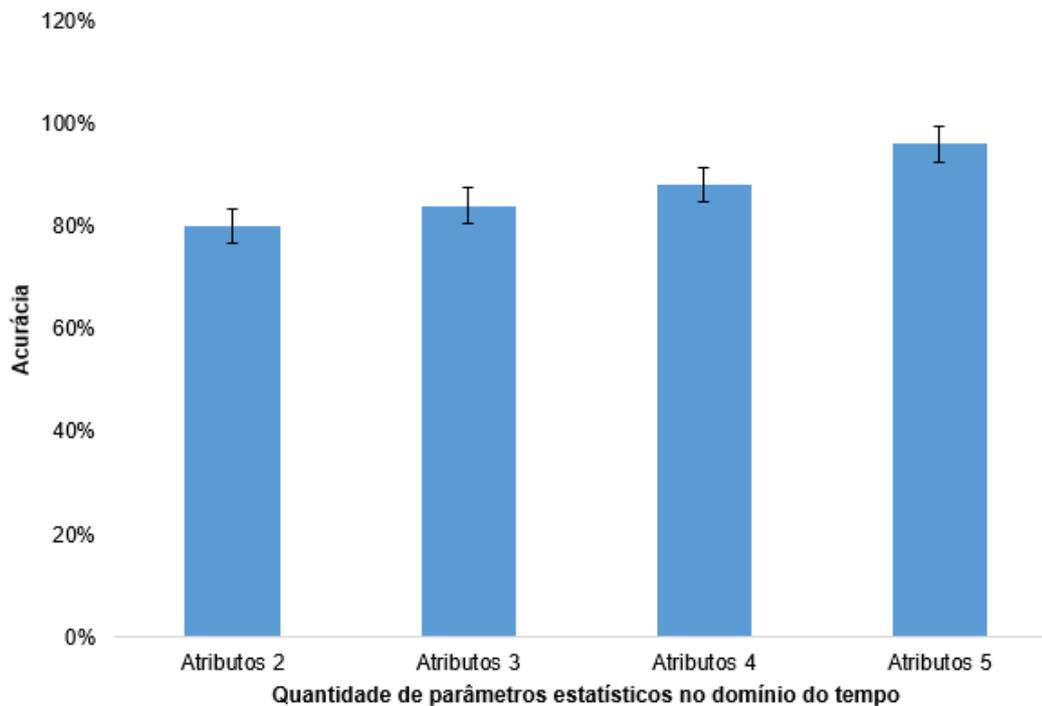
Figura 36 – Precisão aplicando a função kernel RBF.



Fonte: Elaborada pela autora (2022)

Analisando a acurácia, observa-se a mesma tendência de melhora com o aumento de número de atributos, como pode ser visto na Figura 37. Utilizando 5 atributos a acurácia da classificação aumentou 16 % quando comparado á acurácia utilizando somente dois atributos.

Figura 37 – Acurácia aplicando a função kernel RBF

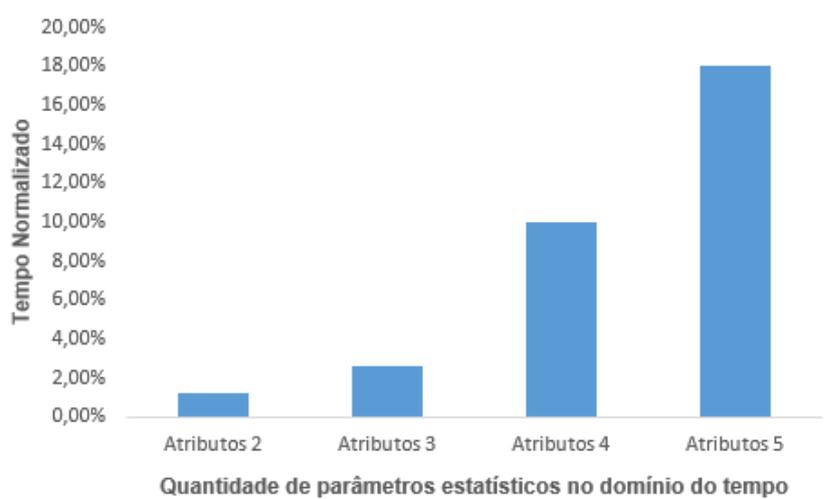


Fonte: Elaborada pela autora (2022)

Uma questão importante é analisar a influência do número de parâmetros no tempo de

treinamento da SVM. Para eliminar o efeito do hardware na velocidade de processamento, o tempo é normalizado em relação ao obtido com 2 parâmetros. A Figura 38 mostra o tempo de treinamento normalizado em função do número de atributos utilizados. Dela, observa-se que aumentando o número de atributos, maior o tempo para treinamento. Quando a rede SVM foi treinada utilizando 5 atributos o tempo aumentou cerca de 18 % em relação ao treinamento da SVM utilizando 2 atributos, o que é aceitável dada a acurácia e a precisão obtidas.

Figura 38 – Tempo de treinamento para função kernel RBF.



Fonte: Elaborada pela autora (2022)

Diante disso, a eliminação dos recursos no modelo SVM teve efeito na classificação, sendo que o melhor *dataset* resultou com precisão de 96% e uma acurácia de 96%. É visível quando aumentar a quantidade de atributos o desempenho do classificador aumenta, esse resultado é devido à quantidade de informações relevantes na categorização das classes.

Com a análise dos resultados do teste e do treinamento, ao comparar a quantidade de atributos, utilizou para validação dos resultados a função kernel RBF com 5 atributos. Pode-se constatar que das 7 amostras para validação obteve 28,6% de erro, na Tabela 15 nota-se a matriz de confusão da validação, das 2 amostras de C a mesma foi categorizada como A.

Tabela 15 – Matriz de confusão da validação para o modelo com dois atributos aplicando a função kernel RBF.

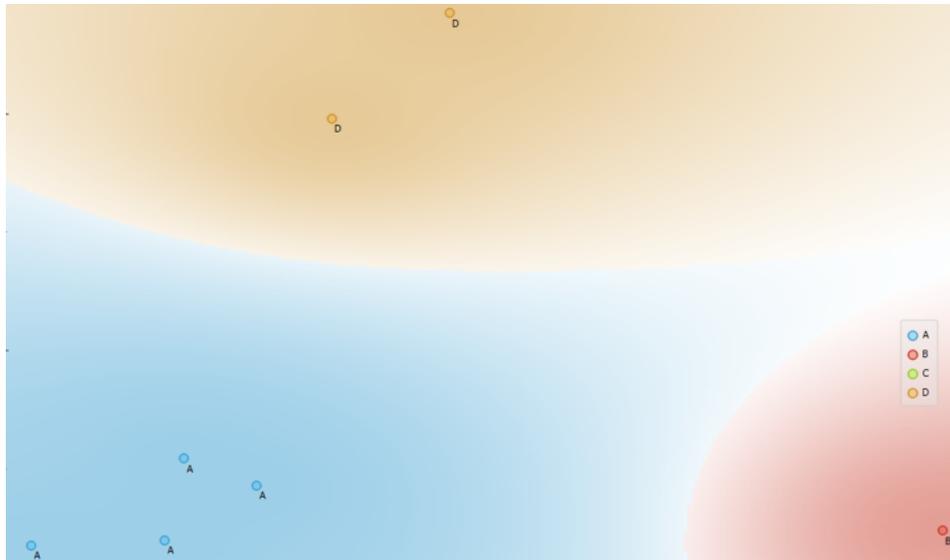
		Classe verdadeira			
		A	B	C	D
Condição prevista	A	2	0	0	0
	B	0	1	0	0
	C	2	0	0	0
	D	0	0	0	2

Fonte: Elaborada pela autora (2022)

Na Figura 39 nota-se separação dos níveis de dureza do aço aplicando a função kernel RBF com cinco atributos. Além disso, pode-se observar a tendência dos pontos e a formação do

hiperplano de separação para os dados de validação como mencionado na Tabela 15e que ser visto na Figura 39 das duas amostras de C todas classificadas como A.

Figura 39 – Aplicação do RBF para cinco atributos.



Fonte: Elaborada pela autora (2022)

## 5 CONSIDERAÇÕES FINAIS

Aplicação da técnica de monitoramento através da medição da corrente do motor do eixo-árvore utilizando um sensor de efeito Hall tem um custo menor do que outros métodos indiretos para medir a força, o sistema apresentou um ótimo desempenho sem dificuldades da instalação na máquina-ferramenta. Além disso, o comportamento da corrente do motor do eixo-árvore em relação à dureza do material corresponde com a literatura, quanto maior o valor de RMS maior a dureza do material.

Por outro lado, a corrente do motor do eixo-árvore pode sofrer influência de ruídos elétricos e para aumentar a confiabilidade foi necessário realizar a fusão de mais um sensor, que neste caso foi empregado um sensor INMP4122 para adquirir o som.

Os resultados obtidos da magnitude da pressão sonora ficou evidente que a propriedade do material influencia no sistema. Sendo que, quanto maior a resistência do material, maior a amplitude de vibração e maior o nível do sinal. Portanto, a fusão dos sensores mostrou uma clara evidência do comportamento da propriedade do material.

Com a análise dos dados adquiridos foi aplicado o SVM para classificar o aço SAE 4340 para quatro níveis de dureza: dureza A (32HRC), B (36 HRC), C (42 HRC) e D (46 HRC). Os dados foram classificados corretamente, o melhor resultado foi utilizando a função Kernel RBF.

As comparações feitas com os dados obtidos com o que foi abordado na literatura por: Lorena e Carvalho (2007), Guimarães (2016), Souza (2019 B), Brusamarello *et al.* (2022) e Pang *et al.* (2011) em relação a análise da função kernel trazem uma grande confiabilidade para os resultados obtidos, pois ao aplicar a funções kernel RBF, polinomial e sigmoid o menor erro obtido ao treinar foi com a função kernel RBF utilizando os hiperparâmetro  $C = 100$  e o  $\gamma = 0,01$  empregando 5 atributos foi alcançado 96% de acurácia e 1 erro ao categorizar entre a classe B e C.

Por outro lado, ao utilizar a função kernel RBF foi possível notar que quanto menor a quantidade de atributo, menor a acurácia e maior a dificuldade de distinguir os dados por categoria,

A principal contribuição deste trabalho foi a construção de um sistema inteligente de baixo custo para auxiliar na tomada de decisão no processo de usinagem, visto que: é fácil para instalar, não precisa interromper o processo para medir a dureza do material, o sensor e as placas utilizadas são de baixo custo e implementação do algoritmo SVM não tem custo admissional. Além disso, esse tipo de monitoramento pode auxiliar na identificação do estado da ferramenta de corte.

### 5.1 SUGESTÕES PARA TRABALHOS FUTUROS

- Utilizar outros materiais com durezas diferentes e outras ferramentas de corte;
- Realizar teste com geometria mais complexa;

- Realizar mais ensaio para alimentar o dataset de modo a melhorar a aplicação do SVM
- Combinar outros sensores para monitoramento do processo;
- Aplicar e analisar outras técnicas de aprendizado de máquina;
- Melhorar a programação para obter a classificação direto da máquina.

## REFERÊNCIAS

- ABELLAN-NEBOT, Jose Vicente; SUBIRÓN, Fernando Romero. A review of machining monitoring systems based on artificial intelligence process models. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 47, n. 1, p. 237–257, 2010.
- ALEXANDER, Charles K; SADIKU, Matthew NO. **Fundamentos de circuitos elétricos**. [S.l.]: AMGH Editora, 2013.
- ALMEIDA, Fabiano Ribeiro do Vale. **Análises estatísticas e reconhecimento de padrão aplicados em diagnósticos de defeitos em rolamentos através da análise de vibração**. Tese (Doutorado) — Universidade Federal De Itajubá, Itajubá, 2007.
- ALMEIDA, Marcelo Adriano Marques. **Monitoramento das forças e desgaste da ferramenta durante o fresamento concordante e discordante do aço ABNT-4140**. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, 2019.
- AROEIRA, Carlos. Analisador de vibrações. 2020. Disponível em: <<https://www.d4vib.com/funcoes-de-um-canal-no-dominio-do-tempo-num-analisador-de-vibracoes/>>. Acesso em: 27 Jun. 2022.
- ASILTURK, I; KAHRAMANLI, H; MOUNAYRI, H El. Prediction of cutting forces and surface roughness using artificial neural network (ann) and support vector regression (svr) in turning 4140 steel. **Materials Science and Technology**, Taylor & Francis, v. 28, n. 8, p. 980–986, 2012.
- BARROS, Renato Araujo et al. Caracterização de um aço aisi/sae 4340 com diferentes microestruturas através da técnica de tríplex ataque. **Revista Brasileira de Aplicação de Vácuo**, 2015.
- BAU. Plataforma arduino, universo de possibilidades. 2018. Disponível em: <<https://blog.baudaeletronica.com.br/plataforma-arduino/>>. Acesso em: 24 Jun. 2022.
- BORITH, Taing et al. Prediction of machine inactivation status using statistical feature extraction and machine learning. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 10, n. 21, p. 7413, 2020.
- BRIZOLLA, Rafaela Kauane. **Indústria 4.0-Um estudo de caso na Saur equipamentos S/A**. 52 f. — Univeridade Federal de Santa Maria, Palmeira das Missões, 2019.
- BRUSAMARELLO, Beatriz et al. **Deteção de falhas em rolamentos de motores de indução trifásicos baseada em máquina de vetores de suporte e redes de Bragg em fibra óptica**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2022.
- CAESARENDRA, Wahyu; TIAHJOWIDODO, Tegoeh. A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. **Machines**, Multidisciplinary Digital Publishing Institute, v. 5, n. 4, p. 21, 2017.
- CAGGIANO, Alessandra. Cloud-based manufacturing process monitoring for smart diagnosis services. **International Journal of Computer Integrated Manufacturing**, Taylor & Francis, v. 31, n. 7, p. 612–623, 2018.

CAMPBELL, Colin. An introduction to kernel methods. **Studies in Fuzziness and Soft Computing**, PHYSICA-VERLAG, v. 66, p. 155–192, 2001.

CAMPIDELLI, Augusto Freitas Vieira et al. **Desenvolvimento de um sistema de monitoramento de corrente elétrica para o estudo da usinabilidade do aço UNS S32760**. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, 2020.

CAMPOS, Paulo Henrique da Silva et al. Modelagem e monitoramento da rugosidade da superfície no torneamento do aço aisi h13 temperado usando metodologia de superfície de resposta com análise de som. In: **XXXIV ENCONTRO NACIONAL DE ENGENHARIA DE PRODUCAO**. Joinville, Brasil: [s.n.], 2014.

ÇAYDAŞ, Ulaş; EKICI, Sami. Support vector machines models for surface roughness prediction in cnc turning of aisi 304 austenitic stainless steel. **Journal of intelligent Manufacturing**, Springer, v. 23, n. 3, p. 639–650, 2012.

CIMM. Fresamento: Variáveis e parâmetros de corte. 2022. Disponível em: <[https://www.cimm.com.br/portal/material\\_didatico/4861-fresamento-variaveis-e-parametros-de-corte](https://www.cimm.com.br/portal/material_didatico/4861-fresamento-variaveis-e-parametros-de-corte)>. Acesso em: 12 Jun. 2022.

COSTA, Cesar da. **Processamento de Sinais para engenheiros: Teoria e prática**. [S.l.]: Editora Bonecker, 2018.

CUI, Jin et al. 3d printing in the context of cloud manufacturing. **Robotics and Computer-Integrated Manufacturing**, Elsevier, v. 74, p. 102256, 2022.

DINIZ A. E; MARCONDES, F. C; COPPINI N. L. **Tecnologia da usinagem dos materiais**. [S.l.]: Artliber, 2013.

ERBOZ, Gizem. How to define industry 4.0: main pillars of industry 4.0. **Managerial trends in the development of enterprises in globalization era**, p. 761–767, 2017.

FERRARESI, Dino. **Fundamentos da usinagem dos metais**. [S.l.]: Editora blucher, 2018.

FERRER, Borja Ramis et al. Connecting web-based iot devices to a cloud-based manufacturing platform. In: IEEE. **IECON 2017-43rd Annual Conference of the IEEE Industrial Electronics Society**. [S.l.], 2017. p. 8628–8633.

FRIGIERI, Edielson Prevato. Reconhecimento de padrões em energia de emissões acústicas na frequência audível em processos de torneamento de aços endurecidos. 2016.

GARCIA, Ubirajara. Estudo da aplicação de mínima quantidade de fluido no fresamento de acabamento da liga Ti-6Al-4V. Universidade Estadual Paulista (UNESP), 2015.

GIMENEZ, Mayther Freire. **Monitoramento do comportamento da corrente elétrica no processo de fresamento**. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2020.

GUIMARÃES, Ana Paula Alves. Utilização do algoritmo de aprendizado de máquinas para monitoramento de falhas em estruturas inteligentes. Universidade Estadual Paulista (UNESP), 2016.

HE, Dan; NI, Zexing; WANG, Xiufeng. Online grinding chatter detection based on minimum entropy deconvolution and autocorrelation function. **The International Journal of Advanced Manufacturing Technology**, Springer, p. 1–11, 2022.

HUERTA-ROSALES, Jose R et al. Short-circuited turn fault diagnosis in transformers by using vibration signals, statistical time features, and support vector machines on fpga. **Sensors**, MDPI, v. 21, n. 11, p. 3598, 2021.

KOIKE, Ryo; OHNISHI, Kouhei; AOYAMA, Tojiro. A sensorless approach for tool fracture detection in milling by integrating multi-axial servo information. **CIRP Annals**, Elsevier, v. 65, n. 1, p. 385–388, 2016.

KONG, Dongdong et al. Tool wear monitoring based on kernel principal component analysis and v-support vector regression. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 89, n. 1, p. 175–190, 2017.

KOTHURU, Achyuth; NOOKA, Sai Prasad; LIU, Rui. Audio-based tool condition monitoring in milling of the workpiece material with the hardness variation using support vector machines and convolutional neural networks. **Journal of Manufacturing Science and Engineering**, American Society of Mechanical Engineers, v. 140, n. 11, p. 111006, 2018.

KRISHNAKUMAR, P; RAMESHKUMAR, K; RAMACHANDRAN, KI. Machine learning based tool condition classification using acoustic emission and vibration data in high speed milling process using wavelet features. **Intelligent Decision Technologies**, IOS Press, v. 12, n. 2, p. 265–282, 2018.

KROLCZYK, G; NIESLONY, P; LEGUTKO, S. Microhardness and surface integrity in turning process of duplex stainless steel (dss) for different cutting conditions. **Journal of Materials Engineering and Performance**, Springer, v. 23, n. 3, p. 859–866, 2014.

LIMA, Thiago Fernandes Oliveira de. **Desenvolvimento de sistema de baixo custo para monitoramento e controle de processos de usinagem usando Raspberry Pi®**. Dissertação (Mestrado) — Universidade Estadual Paulista (Unesp), Guaratinguetá, 2021.

LIU, Yen-Po; KILIC, Zekai Murat; ALTINTAS, Yusuf. Monitoring of in-process force coefficients and tool wear. **CIRP Journal of Manufacturing Science and Technology**, Elsevier, v. 38, p. 105–119, 2022.

LORENA, Ana Carolina; CARVALHO, André CPLF De. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.

LU, Ming-Chyuan; WAN, Bing-Syun. Study of high-frequency sound signals for tool wear monitoring in micromilling. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 66, n. 9-12, p. 1785–1792, 2013.

MOHAMED, Ayman et al. Tool condition monitoring for high-performance machining systems—a review. **Sensors**, MDPI, v. 22, n. 6, p. 2206, 2022.

MOSCA, Edoardo. **Kernel Methods, Multiclass Classification and Applications to Computational Molecular Biology**. Dissertação (Mestrado) — Università Degli Studi Di Firenze, 2004.

MOURTZIS, Dimitris; MILAS, Nikolaos; VLACHOU, Aikaterini. An internet of things-based monitoring system for shop-floor control. **Journal of Computing and Information Science in Engineering**, American Society of Mechanical Engineers Digital Collection, v. 18, n. 2, 2018.

MOURTZIS, Dimitris et al. Cloud-based adaptive process planning considering availability and capabilities of machine tools. **Journal of Manufacturing Systems**, Elsevier, v. 39, p. 1–8, 2016.

MURARO, Tiago Rossato. **Monitoramento do desgaste da ferramenta no processo de fresamento de aço P20 através da medição da potência do motor**. Dissertação (Mestrado) — Engenharia Mecânica, Caxias do Sul /Santa Catarina, 2020.

NEGRI, Rogério Galante. **Máquina de Vetores de Suporte Adaptativa ao Contexto: formalização e aplicações em Sensoriamento Remoto**. Tese (Doutorado) — (Computação Aplicada)-Instituto Nacional de Pesquisas, 2013.

NIU, Dongxiao; DAI, Shuyu. A short-term load forecasting model with a modified particle swarm optimization algorithm and least squares support vector machine based on the denoising method of empirical mode decomposition and grey relational analysis. **Energies**, Multidisciplinary Digital Publishing Institute, v. 10, n. 3, p. 408, 2017.

OLIVEIRA, Everton Gustavo de. Efeito dos parâmetros de tratamento térmico na microestrutura e nas propriedades dos aços sae 4340 e 8640 temperados e revenidos. **Trabalho de Graduação apresentado pelo Centro Federal de Educação Tecnológica de Minas Gerais pelo Curso de Engenharia de Materiais**, 2014.

OLIVEIRA, Greici. **NodeMCU – Uma plataforma com características singulares para o seu projeto IoT**. 2016. Disponível em: <<https://blogmasterwalkershop.com.br/embarcados/nodemcu/nodemcu-uma-plataforma-com-caracteristicas-singulares-para-o-seu-projeto-iot>>. Acesso em: Junho de 2022.

OUADAH, Abdelfettah; ZEMMOUCHI-GHOMARI, Leila; SALHI, Nedjma. Selecting an appropriate supervised machine learning algorithm for predictive maintenance. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 119, n. 7, p. 4277–4301, 2022.

PANDIYAN, Vigneashwara et al. Identification of abnormal tribological regimes using a microphone and semi-supervised machine-learning algorithm. **Friction**, Springer, v. 10, n. 4, p. 583–596, 2022.

PANG, Hong-xia et al. Novel linear search for support vector machine parameter selection. **Journal of Zhejiang University SCIENCE C**, Springer, v. 12, n. 11, p. 885–896, 2011.

PEIXOTO, João Alvarez. **ESP8266 NodeMCU: do pisca led à internet das coisas**. 1ª. ed. Porto Alegre: [s.n.], 2021. Disponível em: <[https://scholar.google.com.br/scholar?hl=pt-BR&as\\_sdt=0%2C5&q=livro+ESP8266+NodeMCU%3A+do+pisca+led+%3%A0+internet+das+coisas&btnG=>](https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=livro+ESP8266+NodeMCU%3A+do+pisca+led+%3%A0+internet+das+coisas&btnG=>)>.

PIMENOV, Danil Yu et al. Artificial intelligence systems for tool condition monitoring in machining: Analysis and critical review. **Journal of Intelligent Manufacturing**, Springer, p. 1–43, 2022.

PONTES, Fabrício José. Projeto otimizado de redes neurais artificiais para predição da rugosidade em processos de usinagem com a utilização da metodologia de projeto de experimentos. Universidade Estadual Paulista (UNESP), 2011.

RAFEZI, Hamed; AKBARI, Javad; BEHZAD, Mehdi. Tool condition monitoring based on sound and vibration analysis and wavelet packet decomposition. In: IEEE. **2012 8th International Symposium on Mechatronics and its Applications**. [S.l.], 2012. p. 1–4.

RAJA, Emerson et al. Tool flank wear condition monitoring during turning process by svd analysis on emitted sound signal. **European Journal of scientific research**, v. 49, n. 4, p. 503–509, 2011.

RECH, J et al. Reduction of noise during milling operations. **CIRP Journal of Manufacturing Science and Technology**, Elsevier, v. 18, p. 39–44, 2017.

RITOU, Mathieu et al. Angular approach combined to mechanical model for tool breakage detection by eddy current sensors. **Mechanical Systems and Signal Processing**, Elsevier, v. 44, n. 1-2, p. 211–220, 2014.

ROBÓTICA, Casa da. **Placa Raspberry Pi Zero W com Wifi e Bluetooth 4.0 | 1Ghz | 512 Mb de RAM DDR2 | Saída Mini HDMI**. 2022.

ROZO-GARCÍA, Florelva. Revisión de las tecnologías presentes en la industria 4.0. **Revista UIS Ingenierías**, v. 19, n. 2, p. 177–192, 2020.

SANTOS, Bruno Strippoli dos et al. Automação de casas e estabelecimentos comerciais através de microcontroladores: uma revisão da aplicabilidade do arduino. 2020. Disponível em: <<http://ric.cps.sp.gov.br/handle/123456789/6732>>.

SANTOS, Everaldo José Rabêlo dos. Previsão de precipitação usando máquinas de vetores de suporte visando sua implementação em sistemas embarcados. 2019.

SAUCEDO-DORANTES, Juan Jose et al. Diagnosis methodology for identifying gearbox wear based on statistical time feature reduction. **Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science**, SAGE Publications Sage UK: London, England, v. 232, n. 15, p. 2711–2722, 2018.

SCHÖLKOPF, Bernhard et al. **Learning with kernels: support vector machines, regularization, optimization, and beyond**. [S.l.]: MIT press, 2002.

SILVA, Rafael Gomes da et al. Aquisição da potência ativa no fresamento frontal utilizando um sistema de baixo custo. **Brazilian Journal of Development**, v. 7, n. 5, p. 51597–51610, 2021.

SILVA, Rodrigo Henriques Lopes. **Monitoramento do desgaste de ferramentas no fresamento de topo através dos sinais de potência e emissão acústica e redes neurais**. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia/MG, 2010.

SINGLA, Rajesh et al. Comparison of svm and ann for classification of eye events in eeg. **Journal of Biomedical Science and Engineering**, Scientific Research Publishing, v. 4, n. 1, p. 62, 2011.

SOUSA, Denis Barbosa et al. Monitoramento da potência ativa na usinagem utilizando um sistema de baixo custo. In: **9º Congresso Brasileiro de Engenharia de Fabricação**. Joinville, Brasil: [s.n.], 2017. p. 2–8.

- SOUZA, J. A. **Apostila: ENG03082 – Monitoramento De Processos De Usinagem**. [S.l.]: Porto Alegre, 2015.
- SOUZA, Jusley da Silva. **Análise de atributos de classificação para o diagnóstico de falhas em rolamentos baseado em SVM**. Dissertação (Mestrado) — Universidade Federal do Pará, 2019 b.
- SOUZA, Lucas Melegari de. **Desenvolvimento de um sistema de baixo custo para o monitoramento do desgaste de ferramenta de corte via corrente elétrica**. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2019a.
- SUNNY, SM Nahian Al; LIU, Xiaoqing F; SHAHRIAR, Md Rakib. Communication method for manufacturing services in a cyber–physical manufacturing cloud. **International Journal of Computer Integrated Manufacturing**, Taylor & Francis, v. 31, n. 7, p. 636–652, 2018.
- TAHIR, NHM et al. Monitoring the flank wear using piezoelectric of rotating tool of main cutting force in end milling. **Jurnal Teknologi**, v. 78, n. 6-10, 2016.
- THAMES, Lane; SCHAEFER, Dirk. Software-defined cloud manufacturing for industry 4.0. **Procedia cirp**, Elsevier, v. 52, p. 12–17, 2016.
- UHLMANN, Eckart et al. Smart wireless sensor network and configuration of algorithms for condition monitoring applications. **Journal of Machine Engineering**, v. 17, 2017.
- VITÓRIA, Bruno César Rocha. **Análise do sinal de vibração no fresamento do aço AISI 4340 com ferramentas desgastadas**. Dissertação (Mestrado) — Universidade Federal Rio Grande do Norte, Natal, 2016.
- WANG, Shuhui et al. A data indicator-based deep belief networks to detect multiple faults in axial piston pumps. **Mechanical Systems and Signal Processing**, Elsevier, v. 112, p. 154–170, 2018.
- WEGENER, Konrad et al. Noise and vibrations in machine tools. **CIRP Annals**, Elsevier, v. 70, n. 2, p. 611–633, 2021.
- XU, Xun. From cloud computing to cloud manufacturing. **Robotics and computer-integrated manufacturing**, Elsevier, v. 28, n. 1, p. 75–86, 2012.
- ZHOU, Yuqing et al. Tool wear condition monitoring based on a two-layer angle kernel extreme learning machine using sound sensor for milling process. **Journal of Intelligent Manufacturing**, Springer, p. 1–12, 2020.
- ZURITA-HURTADO, Omar José; GRACI-TIRALONGO, Verónica Carmen Di; CAPACE-AGUIRRE, María Cristina. Surface hardness prediction based on cutting parameters in turning of annealed aisi 1020 steel. **Dyna**, 2006, Revista DYNA, v. 84, n. 203, p. 31–36, 2017.