

LUCAS COSTA BRITO

**DETERMINAÇÃO DA CONDIÇÃO DE DESGASTE DA
FERRAMENTA DE CORTE VIA MONITORAMENTO
DE VIBRAÇÃO E INTELIGÊNCIA ARTIFICIAL**



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA**

2018

LUCAS COSTA BRITO

**DETERMINAÇÃO DA CONDIÇÃO DE DESGASTE DA FERRAMENTA
DE CORTE VIA MONITORAMENTO DE VIBRAÇÃO E
INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **MESTRE EM ENGENHARIA MECÂNICA**.

Área de Concentração: Mecânica dos Sólidos e Vibração

Orientador: Prof. Dr. Marcus Antonio Viana Duarte

Co-Orientador: Prof. Dr. Márcio Bacci da Silva

UBERLÂNDIA - MG

2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

B862d Brito, Lucas Costa, 1993-
2018 Determinação da condição de desgaste da ferramenta de corte via monitoramento de vibração e inteligência artificial [recurso eletrônico] / Lucas Costa Brito. - 2018.

Orientador: Marcus Antonio Viana Duarte.

Coorientador: Márcio Bacci da Silva.

Dissertação (mestrado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Mecânica.

Modo de acesso: Internet.

Disponível em: <http://dx.doi.org/10.14393/ufu.di.2018.1213>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia mecânica. 2. Ferramentas. 3. Desgaste mecânico. 4. Usinagem. I. Duarte, Marcus Antonio Viana (Orient.). II. Silva, Márcio Bacci da, 1964- (Coorient.). III. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Engenharia Mecânica. IV. Título.

CDU: 621

Maria Salete de Freitas Pinheiro - CRB6/1262



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Engenharia Mecânica
 Av. João Naves de Ávila, nº 2121, Bloco 1M, Sala 212 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4282 - www.posgrad.mecanica.ufu.br - secposmec@mecanica.ufu.br



TERMO

ALUNO: Lucas Costa Brito

MATRÍCULA: 11712EMC010

ÁREA DE CONCENTRAÇÃO: Mecânica dos Sólidos e Vibrações

LINHA DE PESQUISA: Dinâmica de Sistemas Mecânicos

PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA: NÍVEL MESTRADO

TÍTULO DA DISSERTAÇÃO: “Determinação da Condição de Desgaste da Ferramenta de Corte via Monitoramento de Vibração e Inteligência Artificial”

ORIENTADOR: Prof. Dr. Marcus Antonio Viana Duarte

COORIENTADOR: Prof. Dr. Márcio Bacci da Silva

A Dissertação foi **APROVADA** em reunião privada, realizada no Anfiteatro C - Bloco 50, Campus Santa Mônica, em 27 de agosto de 2018, às 09:00 horas, com a seguinte Banca Examinadora:

Prof. Dr. Marcus Antonio Viana Duarte - UFU

Prof. Dr. Márcio Bacci da Silva - UFU

Prof. Dr. Arthur Alves Fiocchi - UFU

Prof. Dr. Francisco Paulo Lépore Neto - UFU

Prof. Dr. Jânes Landre Júnior - PUC/MG

Uberlândia, 27 de agosto de 2018



Documento assinado eletronicamente por **Marcus Antonio Viana Duarte, Professor(a) do Magistério Superior**, em 27/08/2018, às 12:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Francisco Paulo Lepore Neto, Professor(a) do Magistério Superior**, em 27/08/2018, às 12:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcio Bacci da Silva, Professor(a) do Magistério Superior**, em 27/08/2018, às 12:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Arthur Alves Fiocchi, Professor(a) do Magistério Superior**, em 27/08/2018, às 12:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **JANES LANDRE JÚNIOR, Usuário Externo**, em 27/08/2018, às 12:22, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0670559** e o código CRC **85F16680**.

*Dedico esse trabalho a todos
que partilham dessa vitória.*

"Don't find fault. Find a remedy".

Henry Ford

AGRADECIMENTOS

À Universidade Federal de Uberlândia e à Faculdade de Engenharia Mecânica por toda a infraestrutura e auxílio.

Ao grande mestre Prof. D. Sc. Marcus Antônio Viana Duarte, por toda a orientação durante esse caminho.

Ao Prof. D.Sc. Márcio Bacci da Silva, por ter aceitado esse projeto, e contribuído imensamente com sua grande experiência.

À minha família por todo o suporte e carinho. Em especial, ao meu eterno orientador e pai, Prof. D.Sc. Jorge Nei Brito, à minha mãe, pelo amor e sabedoria única e à Dona Madá para sempre lembrar da alegria de viver.

À minha namorada e sua família pelo amor, atenção e compreensão sempre que necessário.

A todos os colegas e técnicos do Laboratório de Acústica e Vibrações e Laboratório de Ensino e Pesquisa em Usinagem pela contribuição no desenvolvimento desse trabalho.

Aos meus amigos pelo incentivo em sempre buscar os objetivos traçados.

Ao CNPq pelo suporte financeiro.

BRITO, L. C. **Determinação da condição de desgaste da ferramenta de corte via monitoramento de vibração e inteligência artificial.** 2018. 109 f. Dissertação de Mestrado, Universidade Federal de Uberlândia, Uberlândia.

Resumo

Uma das consequências mais importantes no processo de usinagem é o desgaste da ferramenta. Assim, monitorar o desgaste das ferramentas de corte torna-se essencial para garantir o sucesso do produto, aumentar a produtividade e evitar danos catastróficos ao equipamento. Como o desgaste está relacionado às vibrações do processo, o sinal de vibração pode ser usado para monitorá-lo. Este trabalho apresenta uma nova abordagem para a identificação do estado de desgaste de uma ferramenta durante o torneamento do aço VC 131 AISI D6, utilizando técnicas conhecidas com baixo custo computacional, que podem fornecer uma futura aplicação industrial para identificação do momento ideal de troca da ferramenta. Para atingir este objetivo, os sinais de vibração foram medidos durante cada etapa de torneamento. Em seguida, utilizou-se um método de inteligência artificial de classificação (*W-kNN*) com parâmetros de entrada extraídas dos sinais de vibração para identificar o estágio de desgaste da ferramenta de corte. Os testes foram realizados com ferramentas sob diferentes condições de desgaste, medidas antes e depois de cada etapa de torneamento. Os resultados mostram que a combinação da técnica de inteligência artificial utilizada com os parâmetros vibratórios extraídos através de técnicas estatísticas clássicas, pode prever com sucesso a condição de desgaste das ferramentas de corte, e certamente pode ser usada como um sistema de monitoramento no meio industrial.

Palavras chave: Monitoramento do desgaste de ferramenta, Peso k-Vizinhos Próximos (*W-kNN*), Parâmetros Vibratórios, Torneamento Aço AISI D6.

BRITO, L. C. **Determination of the wear condition of the cutting tool through vibration monitoring and artificial intelligence.** 2018. 109 f. M. Sc. Dissertation, Universidade Federal de Uberlândia, Uberlândia.

Abstract

One of the most important consequence in machining process is the tool wear. Thus, monitoring the wear of cutting tools becomes essential to ensure product success, increase productivity and avoid catastrophic damages to the equipment. Since wear is related to the vibrations of the process the vibration signal can be used to monitor it. This work presents a new approach for identification of wear condition of a tool during turning operation of VC 131 steel (AISI D6) using well known techniques with low computational cost which can provide a future industrial application to identify the ideal moment of tool change. To achieve this purpose, the vibration signals were measured during each turning step. Then, an artificial classification intelligence method (W-kNN) with features extracted from the vibration signals was used to identify the wear stage. Tests were performed with tools under different wear conditions, which were measured before and after each turning step. The results show that the combination of artificial classification intelligence method with vibratory features can successfully predict the lifespan of cutting tools which can certainly be used as an industrial tool wear-monitoring system.

Keywords: Tool wear monitoring, Weighted k-Nearest Neighbor, Vibratory Features, VC 131 AISI D6 Steel Turning.

LISTA DE FIGURAS

Figura 2.1 - Operação de torneamento.....	6
Figura 2.2 - Tipos de desgaste em ferramentas de corte.....	7
Figura 2.3 - Caracterização do desgaste de flanco.....	8
Figura 2.4 - Tipos de assimetria.....	12
Figura 2.5 - Tipos de achatamento da Distribuição Normal.....	12
Figura 2.6 - Medidas de amplitude.....	13
Figura 2.7 - Análise de envelope utilizando a Transformada de Hilbert.....	15
Figura 2.8 - Exemplo de Gráfico <i>Boxplot</i>	18
Figura 2.9 - Exemplo de classificação do kNN com dois rótulos de classe e $k=10$	22
Figura 2.10 - Cálculo da distância entre os hiperplanos.....	24
Figura 3.1 - Fluxograma do resumo da metodologia.....	26
Figura 3.2 - Esquema de montagem dos equipamentos.....	27
Figura 3.3 - Torno CNC ROMI Multiplic-35D.....	28
Figura 3.4 - Peça usinada.....	28
Figura 3.5 - Ferramenta de corte utilizada.....	29
Figura 3.6 - Porta ferramenta.....	29
Figura 3.7 - Posição dos acelerômetros.....	30
Figura 3.8 - Amplificadores de cargas.....	31
Figura 3.9 - Placa National Instruments.....	32
Figura 3.10 - Microscópio SZ61 - Olympus.....	33
Figura 3.11 - Microscópio eletrônico de varredura TM3 000.....	33
Figura 3.12 - Esquema da divisão da peça a ser usinada.....	34
Figura 3.13 - Curva de desgaste de flanco máximo para a aresta F02A1.....	35
Figura 3.14 - Curva de desgaste para as arestas F02A1, F03A1, F04A1, F05A1 e F06A1.....	37
Figura 3.15 - FFT do sinal.....	39
Figura 3.16 - Diagramas <i>Boxplot</i> Posição Horizontal.....	46
Figura 3.17 - Diagramas <i>Boxplot</i> Posição Vertical.....	48
Figura 3.18 - Diagramas <i>Boxplot</i> Posição Vertical e Horizontal.....	50
Figura 4.1 - Taxa de acerto final para as posições testadas.....	58
Figura 4.2 - Comparação da probabilidade de erro em relação a quantidade de vizinhos para o método kNN e W-kNN.....	60

Figura 4.3 - Taxa de acerto do método W-kNN em função da quantidade de número de vizinhos (k).....	61
Figura 4.4 - Representação dos valores para os cinco parâmetros utilizados.....	63
Figura 4.5 - Representação das arestas de corte após o final dos testes. Fonte: Autor (2018).	65

LISTA DE TABELAS

Tabela 3.1 - Material da peça utilizado e suas respectivas características.....	28
Tabela 3.2 - Parâmetros de corte.....	29
Tabela 3.3 - Especificação dos acelerômetros.	30
Tabela 3.4 - Identificação das aristas de corte.	34
Tabela 3.5 - Resumo dos testes.....	37
Tabela 3.6 - Sintomas calculados no domínio do tempo.	38
Tabela 3.7 - Sintomas calculados relacionados a Análise de Envelope.	40
Tabela 3.8 - Sintomas calculados em função de regiões do espectro.	42
Tabela 3.9 - Seleção dos melhores parâmetros de acordo com o Teste t.....	45
Tabela 3.10 - Divisão dos subgrupos de treinamento, teste e validação - posição horizontal..	53
Tabela 3.11 - Divisão dos subgrupos de treinamento, teste e validação - posição vertical.	53
Tabela 3.12 - Divisão dos subgrupos de treinamento, teste e validação posição vertical horizontal.	54
Tabela 4.1 - Resultado do teste para as Técnicas de Inteligência Artificial.	57
Tabela 4.2 - Parâmetros selecionados.....	58
Tabela 4.3 - Análise dos erros de classificação em relação ao desgaste.....	62
Tabela A2.1 - Resultados dos testes para o Grupo I.....	83
Tabela A2.2 - Resultados dos testes para o Grupo II.....	84
Tabela A3.1 - Resultados do Teste F- Snedecor.....	90
Tabela A4.1 - Resultados do Teste t.....	94
Tabela A5.1 - Resultados dos testes usando W-kNN - Posição Vertical e Horizontal.....	98
Tabela A5.2 - Resultados dos testes usando W-kNN - Posição Horizontal.	100
Tabela A5.3 - Resultados dos testes usando W-kNN - Posição Vertical.....	101
Tabela A5.4 - Resumo dos resultados para as posições testadas.....	103
Tabela A6.1 - Resultados dos testes em relação a quantidade de vizinhos para W-kNN.....	105
Tabela A6.2 - Resumo do resultados dos testes em relação a quantidade de vizinhos para W- kNN.....	109

LISTA DE SÍMBOLOS

Letras arábicas

D_i	Diâmetro inicial
D_f	Diâmetro final
N	Rotação da peça
$a_p (p_c)$	Profundidade de corte
f	Avanço
V_c	Velocidade de corte
V_f	Velocidade de avanço
VB_{Bmax}	Desgaste de flanco máximo
VB_B	Desgaste de flanco médio
$x(t)$	Função que define o sinal no domínio do tempo
T	Período
n	Tamanho da população
x_i	Valor da amostral
\bar{x}	Média amostral
Sk	<i>Skewness</i> (Assimetria)
a_4	Coefficiente de curtose
F_c	Fator de crista
K_4	Parâmetro K_4
S_{rms}	Nível de energia <i>RMS</i>
s	Desvio padrão
F	Valor da estatística do Teste F-Snedecor
t	Valor da estatística do Teste t
$t_{critico}$	Valor crítico do Teste t
r	Valor da estatística do Critério de Chauvenet
R_c	Valor crítico do Critério de Chauvenet
d_i	Distância euclidiana da amostra até o ponto o vizinho avaliado
k	Número de vizinhos
p	Pontos n-dimensionais
q	Pontos n-dimensionais

H	Hiperplano
Y	Distância entre o hiperplano e hiperplano de separação
df	Resolução em frequência

Letras gregas

σ	Desvio padrão amostral
α	Nível de significância
μ	Média amostral

Símbolos e siglas

<i>RMS</i>	Root mean square (Valor médio quadrático)
<i>FFT</i>	<i>Fast Fourier Transform</i> (Transformada Rápida de Fourier)
<i>DFT</i>	<i>Discrete Foureir Trasnform</i> (Transformada Discreta de Fourier)
<i>kNN</i>	<i>k-Nearest Neighbor</i> (k-Vizinhos Próximos)
<i>SVM</i>	<i>Support Vector Machines</i> (Máquina de vetores de suporte)
<i>W-kNN</i>	<i>Weighted k-Nearest Neighbor</i> (k-Vizinhos Próximos com peso)
<i>SOM</i>	<i>Self organizing map</i> (Mapas auto-organizáveis)
C	Carbono
Cr	Cromo
W	Tungstênio
V	Vanádio
ABNT	Associação Brasileira de Normas Técnicas
CBN	Nitreto cúbico de boro
F02A1	Ferramenta 02 Aresta 01
F02A2	Ferramenta 02 Aresta 02
F03A1	Ferramenta 03 Aresta 01
F04A1	Ferramenta 04 Aresta 01
F05A1	Ferramenta 05 Aresta 01
F06A1	Ferramenta 06 Aresta 01
ISO	<i>International Organization for Standardization</i> (Organização Internacional de Normalização)

SUMÁRIO

CAPÍTULO I.....	1
INTRODUÇÃO.....	1
1.1. Objetivos.....	3
1.2. Organização da dissertação.....	3
CAPÍTULO II.....	5
FUNDAMENTAÇÃO TEÓRICA.....	5
2.1. Processo de torneamento.....	5
2.2. Desgaste de ferramentas.....	6
2.2.1. Formas de desgaste da ferramenta.....	7
2.2.2. Mecanismos de desgaste da ferramenta.....	8
2.3. Monitoramento da ferramenta através do sinal de vibração.....	9
2.4. Parâmetros vibratórios no domínio do tempo.....	10
2.4.1. Média.....	11
2.4.2. Assimetria (Skewness).....	11
2.4.3. Curtose (Kurtosis).....	12
2.4.4. Valor médio quadrático (RMS).....	13
2.4.5. Valor pico.....	14
2.4.6. Valor pico a pico.....	14
2.4.7. Fator de crista.....	14
2.4.8. Fator K4.....	14
2.5. Parâmetros vibratórios no domínio da frequência.....	14
2.5.1. Nível de energia do sinal filtrado em bandas de frequência.....	15
2.5.2. Nível de energia do envelope sinal filtrado em bandas de frequência.....	15
2.6. Técnicas estatísticas.....	16
2.6.1. Teste de homocedasticidade: Teste F-Snedecor.....	16
2.6.2. Teste de comparação das médias populacionais: Teste-t.....	17
2.6.3. Gráfico Boxplot.....	18
2.6.4. Teste de valor extremo: Critério de Chauvenet.....	19
2.7. Técnicas de inteligência artificial.....	20
2.7.1. W-kNN (Weighted k-Nearest Neighbor).....	21
2.7.2. SVM (Support Vector Machines).....	22
2.7.3. Rede Neural SOM (Self organizing map).....	24

CAPÍTULO III.....	26
METODOLOGIA E PROCEDIMENTO EXPERIMENTAL	26
3.1. Bancada experimental.....	27
3.2. Procedimento experimental.....	34
3.3. Procedimento de análise dos sinais	38
3.3.1. Definição dos parâmetros vibratórios	38
3.3.2. Análise dos parâmetros vibratórios	43
3.3.3. Metodologia para a análise dos sinais através das Técnicas de Inteligência Artificial.....	52
CAPÍTULO IV	56
RESULTADOS E DISCUSSÃO.....	56
4.2. Determinação da melhor técnica de classificação.....	56
4.3. Determinação da quantidade de parâmetros de entrada e posição do sensor	57
4.4. Determinação da melhor configuração para o método de inteligência artificial.....	59
4.5. Análise da taxa de acerto final	61
4.6. Análise da forma do desgaste final.....	65
CAPÍTULO V	69
CONCLUSÕES	69
5.1. Principais conclusões.....	69
5.2. Conclusões secundárias.....	70
5.3. Trabalhos futuros	71
REFERÊNCIAS BIBLIOGRÁFICAS.....	72
ANEXO I	78
ESPECIFICAÇÕES TÉCNICAS DOS EQUIPAMENTOS UTILIZADOS	78
I.1. Acelerômetro Brüel & Kjær 4397	78
I.2. Amplificador de carga Brüel & Kjær 2635	78
I.3. Placa de aquisição <i>National Instruments</i> NI USB-9162 NI 9233	79
APÊNDICE I.....	80
ROTINAS UTILIZADA.....	80
APÊNDICE II	83
MEDIÇÕES DE DESGASTE.....	83
APÊNDICE III.....	90

RESULTADOS TESTE DE HOMOCEDASTICIDADE	90
APÊNDICE IV	94
RESULTADOS TESTE DE COMPARAÇÃO DAS MÉDIAS	94
APÊNDICE V.....	98
DETERMINAÇÃO DA QUANTIDADE DE PARÂMETROS.....	98
DE ENTRADA E POSIÇÃO DO SENSOR	98
APÊNDICE VI.....	105
DETERMINAÇÃO DA QUANTIDADE DE VIZINHOS PARA O MÉTODO W-kNN	105

CAPÍTULO I

INTRODUÇÃO

O desgaste da ferramenta de corte é uma das consequências inerentes do processo de usinagem, o que torna o monitoramento da mesma essencial para garantia da qualidade, confiabilidade e produtividade dos sistemas de fabricação. Além de evitar danos catastróficos no equipamento, o monitoramento auxilia no momento ideal de troca da ferramenta, e até mesmo na otimização da produtividade e custos no processo, Mikołajczyk (2018). Estudos mostram que ferramentas de usinagem em máquinas de comando numérico são trocadas com apenas 50 a 80 % de sua vida útil Liu (2018).

Atualmente, a busca por um baixo custo de produção, garantindo a confiabilidade do processo é a busca de todas as empresas do mercado. Nesse cenário, a troca das ferramentas de corte em processos de usinagem é uma atividade que, apesar das recentes evoluções tecnológicas com material e processo, ainda gera grande despesa para o setor industrial.

Ao longo do processo de usinagem, devido principalmente ao desgaste, a ferramenta tem sua geometria inicial alterada, influenciando diretamente na qualidade do produto e nas tolerâncias dimensionais alcançadas. O aumento do raio de ponta da ferramenta, por exemplo, pode influenciar significativamente as tensões residuais numa peça Liu, Takagi, Tsukuda (2004). Além disso, desgastes severos podem resultar na quebra inesperada da ferramenta que, por sua vez, pode ocasionar quebras ainda maiores, como o de componentes da máquina ferramenta Rizal *et al.* (2017). Logo, o monitoramento torna-se essencial dentro de uma linha de produção, tornando possível realizar ações antes que essas falhas catastróficas possam ocorrer, Marques *et al.* (2012).

Em seu estudo, Kannatey-Asibu, Yum e Kim (2017) mostraram que monitorar o desgaste não é uma tarefa simples, principalmente devido à natureza do mesmo. Uma ferramenta que não é monitorada de forma eficiente pode resultar em altos custos de operação e produção.

Normalmente, mais de um mecanismo de desgaste pode estar envolvido no processo. Trent e Wright (2000), por exemplo, identificam seis mecanismos distintos de desgaste em uma ferramenta de usinagem: abrasão, adesão, difusão, cisalhamento superficial a altas temperaturas, deformação plástica e entalhe. A presença de diversos mecanismos de desgaste dificulta ainda mais a determinação dos corretos parâmetros para criação de um sistema que seja capaz de identificá-lo, Nouri *et al.* (2015).

Diversas são as técnicas de monitoramento presentes no mercado. Logo, conhecer as existentes, aprimorá-las e até mesmo desenvolver novas tecnologias significa uma manutenção de melhor qualidade e, conseqüentemente, com menos tempo de horas paradas na planta industrial, Brito (2002).

Segundo Duarte *et al.* (2003), dentre as técnicas de monitoramento direto e indiretas o monitoramento via medições de vibração se destaca pelo fato de o sistema de medição não ser intrusivo, a instrumentação ser relativamente barata e pelos resultados alcançados.

No monitoramento direto outros fatores dificultam ainda mais a determinação da condição de vida da ferramenta, tais como: a presença do fluido de corte e a necessidade de parar a máquina para uma medição mais exata. No caso de medição através da rugosidade da peça, a complexidade das peças torna a medida de rugosidade ainda mais complicada.

Uma forma alternativa para monitorar o desgaste é utilizar métodos indiretos. Ou seja, monitorar e analisar parâmetros obtidos através de sinais de vibração, emissão acústica, força de corte, temperatura de corte, torque e corrente do motor principal, por exemplo.

Diversos estudos, como mostrado na revisão de Zhou e Xue (2018), vêm sendo realizados com objetivo de desenvolver métodos confiáveis para a identificação da condição de desgaste da ferramenta de corte, dentre os quais a aplicação de redes neurais alinhadas com um método de extração dos parâmetros se destaca, Rizal *et al.* (2017), Yen, Lu e Chen (2013), Drouillet *et al.* (2016). Outras pesquisas também mostram métodos de identificação baseado na análise de vibração alinhado a um sistema automático de detecção, Rmili *et al.* (2016) e Da Silva, Da Silva, Haussi (2016) e sistemas neuro-fuzzy Zhang *et al.* (2016). Porém, apesar de haver resultados que relacionem o sinal de vibração com o desgaste da ferramenta, ainda há algumas lacunas existentes dentro da indústria metalmeccânica, Vitória (2016).

Em geral, tem-se que, através da correta seleção dos parâmetros presentes no sinal, pode-se correlacionar o nível de desgaste da ferramenta, possibilitando um correto diagnóstico da condição de vida da mesma. Em contrapartida, devido aos diversos fatores que influenciam o processo de fabricação, determinar os melhores parâmetros dos sinais que caracterizam o processo de desgaste na ferramenta torna-se uma tarefa árdua.

Portanto, o estudo propõe o desenvolvimento de uma estratégia nova, simples e com alta confiabilidade, para aplicação industrial, utilizando uma metodologia de seleção de parâmetros e análise através de técnicas estatísticas e de técnicas de inteligência artificial para identificação da condição de desgaste da ferramenta.

Dessa forma, não haverá necessidade de o operador possuir conhecimento acerca de processamento e análise de sinais, o que tornaria inviável o processo. Após a implementação, o sistema será capaz de operar de forma automática. Possibilitando, dessa forma, a programação pontual das intervenções de manutenção e aumentando a vida útil das ferramentas de corte.

1.1. Objetivos

O objetivo do presente trabalho é identificar o momento ideal para a troca da ferramenta de corte em um processo de torneamento visando o máximo aproveitamento da mesma e, conseqüentemente, aumentando a produtividade da planta industrial. Como método indireto de medição utilizou-se os sinais de vibração da ferramenta de corte, os quais foram coletados e posteriormente analisados através de técnicas estatísticas e de inteligência artificial. Através dessas análises definiu-se os parâmetros vibratórios que possuem maior correlação com a condição de desgaste da ferramenta de corte. Por fim, utilizou-se as técnicas de inteligência artificial para classificação da condição de desgaste da ferramenta.

1.2. Organização da dissertação

O trabalho é dividido em cinco capítulos. No Capítulo I apresenta-se uma introdução teórica sobre o tema da dissertação e seus objetivos, situando a mesma no contexto atual da pesquisa. No Capítulo II tem-se a fundamentação teórica utilizada. O Capítulo III apresenta a metodologia utilizada, assim como o procedimento experimental realizado. No Capítulo IV são

apresentados e discutidos os resultados obtidos com base na metodologia proposta. As principais conclusões e sugestões de trabalhos futuros são apresentados no Capítulo V. Por fim, são apresentados nos Anexos as especificações técnicas dos equipamentos utilizados, e nos Apêndices todas as informações obtidas em cada teste, e as rotinas computacionais utilizadas.

CAPÍTULO II

FUNDAMENTAÇÃO TEÓRICA

Apresenta-se, neste capítulo, a abordagem teórica que fundamenta esta dissertação. Inicialmente apresenta-se os conceitos sobre o processo de torneamento e desgaste de ferramentas de corte. Destaca-se também os métodos utilizados para definição dos sintomas vibratórios. Além disso, são abordados conceitos sobre métodos estatísticos clássicos e de inteligência artificial utilizados.

2.1. Processo de torneamento

A grande maioria dos produtos produzidos pela indústria sofrem algum tipo de processo de usinagem, do qual se destaca o torneamento.

De acordo com Ferraresi (1970), torneamento é um processo mecânico de usinagem que visa obter superfícies de revolução através de uma ou mais ferramentas monocortantes. Basicamente, o processo consiste no avanço da ferramenta, juntamente com a rotação da peça, gerando novas formas.

Definir corretamente as condições de corte e a ferramenta de corte são fatores determinantes para o sucesso no processo. Ambos os parâmetros variam em função do formato e material da peça, máquina ferramenta, tolerâncias de projeto, custo, dentre outros fatores.

No processo de torneamento estão presentes diversas variáveis, sendo algumas das principais destacadas na Fig. 2.1.

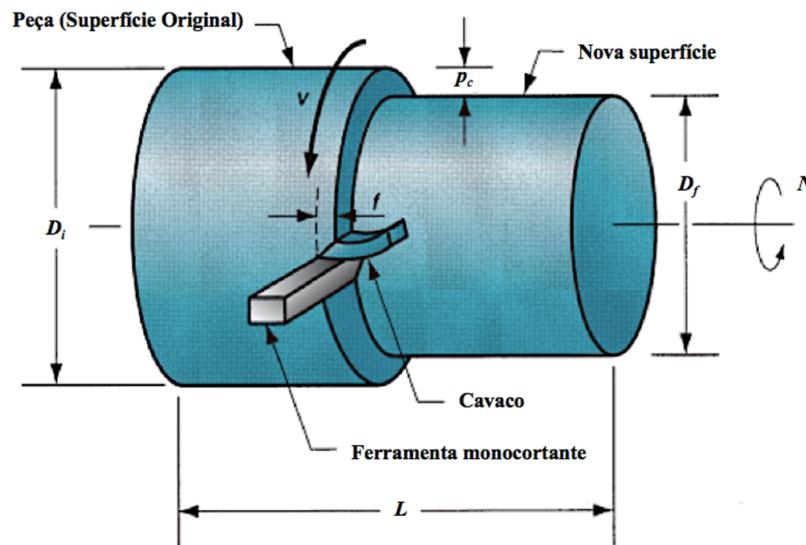


Figura 2.1 - Operação de torneamento. Fonte: Adaptado de Groover (2010).

Analisando a Fig.2.1, tem-se que D_i representa o diâmetro inicial da peça [mm]; D_f o diâmetro final [mm]; N a rotação da peça [rpm]; p_c (a_p) profundidade de corte [mm]; f o avanço [mm/volta]. Além das variáveis representadas, outros importantes parâmetros do processo são: v_c velocidade de corte [m/min] e V_f velocidade de avanço [mm/min].

Uma das consequências do processo de torneamento é a formação de cavaco, que é bastante influenciada pelo tipo de material que está sendo usinado, bem como a geometria da ferramenta de corte, como os ângulos de saída, inclinação, posição e raio de ponta.

Outra consequência da usinagem do material está relacionada a mudança na geometria da ferramenta. Isso, ocorre, principalmente, devido ao contato entre a ferramenta de corte e a peça, podendo ser caracterizadas por avarias e/ou desgastes. O foco desse trabalho é o estudo do monitoramento do desgaste.

2.2. Desgaste de ferramentas

Segundo Rmili *et al.* (2016), a qualidade da peça produzida em operações de usinagem, em relação a tolerâncias dimensional e rugosidade, dependem, principalmente, do estado de desgaste da ferramenta de corte. Isto torna o monitoramento e análise do desgaste procedimentos fundamentais para o sucesso de um processo de fabricação.

De acordo com Trent e Wright (2000) a ferramenta de corte perde suas propriedades de corte devido a três fenômenos: desgaste, deformação plástica e avaria. Conforme mostrado por Machado *et al.* (2011), alguns autores consideram a deformação plástica como um mecanismo de desgaste.

Avaria é o fenômeno que ocorre de maneira repentina e inesperada, causado pela quebra, lascamento ou trinca da aresta de corte, Machado *et al.* (2011). Já o desgaste, de acordo com a ISO 3685 (1993), pode ser definido como a mudança da forma original da aresta durante o corte, devido à perda gradual de material, a qual define, por exemplo, o valor limite de $VB_{Bmax} = 0,6$ mm, para o desgaste de flanco máximo.

Ainda segundo Machado *et al.* (2011) é muito raro ocorrer troca da ferramenta no corte contínuo (torneamento) devido a avarias, salvo situações de mau dimensionamento dos parâmetros de corte e geometria. Dessa forma, tendo em vista o foco do trabalho que é o monitoramento da ferramenta a fim de avaliar a situação de vida da mesma, estudou-se os principais tipos de desgaste.

2.2.1. Formas de desgaste da ferramenta

Os principais tipos de desgaste são mostrados na Fig. 2.2.

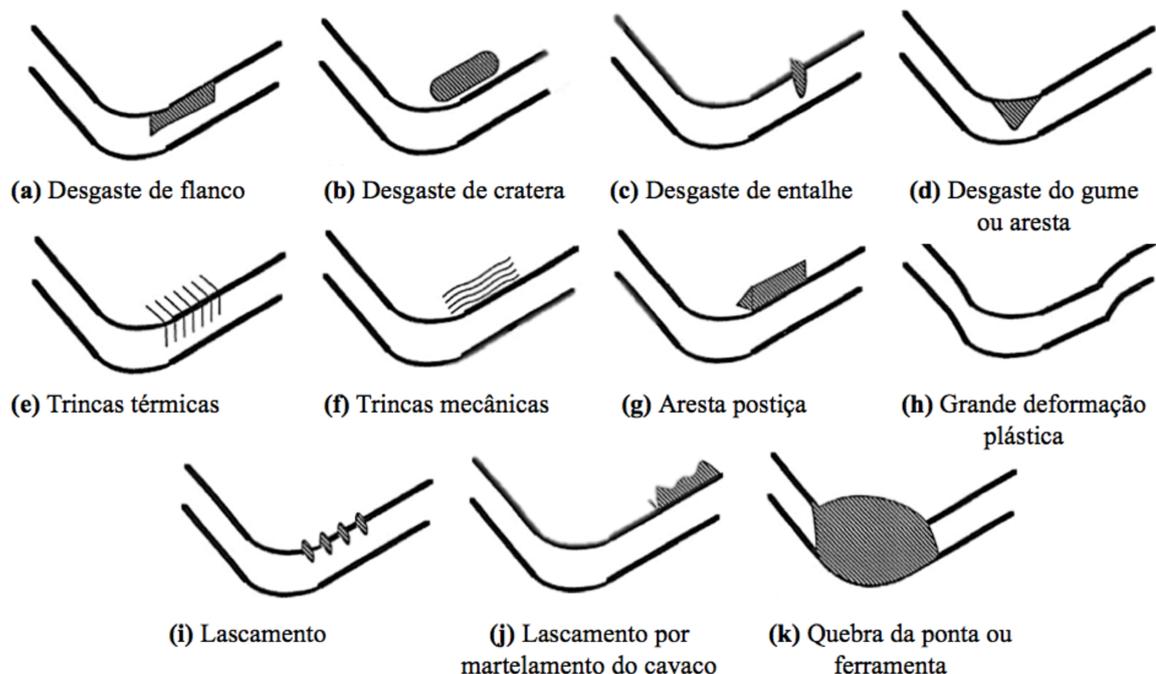


Figura 2.2 - Tipos de desgaste em ferramentas de corte. Fonte: Adaptado de Stephenson e Agapiou (2016).

Dos principais tipos de desgaste mostrados na Fig. 2.2, neste trabalho analisou-se o desgaste de flanco, especificamente o desgaste máximo de flanco (VB_{Bmax}), conforme mostrado na Fig. 2.3.

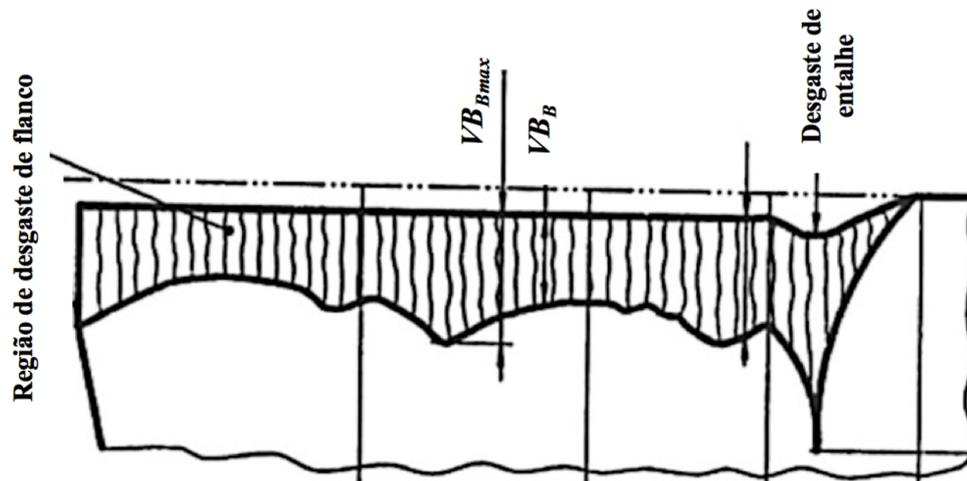


Figura 2.3 - Caracterização do desgaste de flanco. Fonte: Adaptado de Stephenson e Agapiou (2016).

Segundo Diniz; Marcondes; Coppini (2013), o desgaste mais comumente encontrado é o de flanco. Stephenson e Agapiou (2016) reforçam a afirmativa supracitada dizendo ser o tipo mais utilizado para medições de desgaste monitoramento da ferramenta. Em geral, o desgaste de flanco pode ser medido através do desgaste de flanco médio (VB_B) ou desgaste de flanco máximo (VB_{Bmax}), Fig. 2.3.

2.2.2. Mecanismos de desgaste da ferramenta

O desgaste pode ser causado por diversos mecanismos, sendo os principais destacados a seguir.

Segundo Machado *et al.* (2011), geralmente, em condições normais de corte, as formas de desgaste, tais como, difusão, abrasão, adesão e oxidação, estarão presentes, embora uma delas deva prevalecer. Além das formas citadas, Diniz; Marcondes; Coppini (2013) citam como um mecanismo de desgaste muito comum a aresta postiça de corte.

Conforme explicado por Diniz; Marcondes; Coppini (2013), a difusão está intimamente ligada com a temperatura na zona de corte, com a duração do contato e afinidade físico-químico dos elementos envolvidos no processo, ocorrendo em nível atômico. Basicamente, as reações químicas desse processo, geram produtos que são menos resistentes e, conseqüentemente, são removidos rapidamente por abrasão.

A abrasão se faz mais presente no desgaste frontal, mas pode gerar desgaste de cratera também. Em geral, tem-se um desgaste abrasivo quando o material é removido ou deslocado da superfície por partículas duras que podem "estar soltas" entre duas superfícies com movimento relativo, ou que pertencem, a uma das superfícies Machado *et al.* (2011).

O fenômeno da aderência consiste ruptura em um dos metais, e não na superfície de contato. Dessa forma, as partículas da superfície de um material migram para o outro, ocasionando o desgaste, geralmente ocorre em baixas velocidades de corte.

Por fim, a oxidação ocorre devido a presença de altas temperaturas combinando a presença de ar e água. O comportamento perante a oxidação varia de acordo com o material.

2.3. Monitoramento da ferramenta através do sinal de vibração

Conforme citado anteriormente, o desgaste da ferramenta é uma das consequências inerentes do processo de usinagem. Dessa forma, monitorá-lo torna-se fundamental para garantir os resultados esperados no processo de fabricação. Além de garantir a qualidade do produto final, e redução de custo com trocas desnecessárias, o monitoramento do desgaste da ferramenta assegura que a mesma não venha a quebrar prematuramente, o que pode gerar consequências catastróficas para o equipamento.

Diversas são as técnicas utilizadas atualmente para o monitoramento do desgaste de ferramentas e que podem ser divididas em dois grandes grupos: métodos diretos e indiretos, Vitória (2016).

Os métodos diretos de monitoramento consistem na medição da variável avaliada, como, por exemplo, o desgaste da ferramenta ou rugosidade da superfície acabada. Já os métodos indiretos consistem na medição de variáveis indiretas, as quais são correlacionadas através de técnicas com a variável que se deseja avaliar.

Apesar de serem menos precisos que os métodos de monitoramento direto, os métodos indiretos são amplamente aplicados já que na maioria das vezes não é necessário parar o processo de fabricação para medição. Além disso, os métodos de medição diretos possuem elevado custo, e também limitações quanto acesso ao equipamento, espaço para posicionamento dos sensores, problemas de iluminação e uso de fluido de corte, o que pode danificar o sensor.

Dentre os principais métodos de monitoramento direto destacam-se: uso de microscópio, rugosímetro e sensor de proximidade.

De acordo com Nouri *et al.* (2015), para os principais métodos indiretos destacam-se: corrente do motor, força, torque, emissão acústica e vibração.

Atualmente, conforme mostrado por Lauro *et al.* (2014), o monitoramento através do sinal de vibração tem sido usado amplamente para avaliar o desgaste da ferramenta.

Com base nas pesquisas realizadas, tendo em vista o baixo custo em relação a um método de monitoramento direto, a facilidade de implementação do sistema em uma máquina que já se encontra em operação e os resultados previamente obtidos, optou-se por trabalhar apenas com o sinal de vibração.

Além dos fatores supracitados, e de acordo com Rao; Murthy; Rao (2013), à medida que o desgaste da ferramenta de corte aumenta, aumenta-se a amplitude de vibração em todas as bandas de frequência, demonstrando uma boa correlação entre desgaste e vibração, sendo que em algumas bandas, as quais variam de acordo com o caso em estudo, esse aumento é mais significativo. Este fato também justifica o uso do sinal de vibração nesta pesquisa.

Em geral, a vibração no processo de usinagem pode estar correlacionada ao processo de corte e/ou outras fontes como, por exemplo, componentes da própria máquina e outras máquinas próximas (transmissibilidade de vibração pela base).

Verifica-se, portanto, que o monitoramento do desgaste da ferramenta através do sinal de vibração não é uma tarefa simples, uma vez que diversos fatores influenciam no processo de usinagem. Além das possíveis fontes supracitadas, pode-se destacar fatores específicos como: velocidade de corte, rigidez da máquina, avanço, características da ferramenta, propriedades da peça, profundidade de corte, fixação da ferramenta no suporte e condições de usinagem.

Devido à dificuldade de correlacionar as causas de vibração com as variações do sinal de vibração, mesmo analisando no domínio da frequência, utiliza-se métodos para selecionar parâmetros que possam representar o problema e ter uma boa correlação entre o desgaste e o sinal de vibração coletado. Este procedimento torna a correta seleção dos parâmetros vibratórios um fator fundamental para o sucesso do sistema.

2.4. Parâmetros vibratórios no domínio do tempo

A análise e agrupamento de um conjunto de sinais baseia-se principalmente na correta definição dos parâmetros que melhor representam as amostras separadas. Dessa forma é

imprescindível conhecer os parâmetros que podem caracterizar os sinais de vibração estudados nesta dissertação.

Segundo Amaral *et al.* (2016), normalmente a maioria dos conjuntos de dados são de origem gaussiana e podem ser bem caracterizados pela denominada estatística de segunda ordem. Através dela obtém indicadores por simples autocorrelação, onde a multiplicação de duas séries oferece uma caracterização primária dos dados aferidos. No entanto, existem situações em que a autocorrelação não fornece informações suficientes. Nesse caso é necessário utilizar outros métodos para melhorar a caracterização o sinal, como o sinal em estudo.

Dessa forma, quando se tem sinais muito semelhantes, antes e depois da ocorrência do dano, como é o caso do desgaste e quebra da ferramenta, a EOS (Estatística de Ordem Superior) pode fornecer parâmetros que identifiquem pequenas diferenças entre eles possibilitando a detecção de alterações, Amaral *et al.* (2016).

Tendo em vista a dificuldade de correlacionar as variações do sinal de vibração no processo de torneamento com o desgaste, propõe-se a análise de vários parâmetros vibratórios que posteriormente serão usados no método de inteligência artificial para identificação da condição de desgaste da ferramenta. Inicialmente será realizada a análise no domínio do tempo onde os parâmetros estudados serão apresentados.

2.4.1. Média

A média indica a quantidade física da amplitude em um determinado tempo, conforme Eq. 2.1, onde $x(t)$ é a função que define o sinal no domínio do tempo e T o período.

$$\mu = \frac{1}{T} \int_0^T x(t) dt \quad (2.1)$$

2.4.2. Assimetria (*Skewness*)

A assimetria corresponde ao grau de desvio, ou afastamento da simetria, de uma distribuição. Em outras palavras, a distribuição é considerada assimétrica à direita, ou positiva, quando possui um prolongamento (cauda) mais longo à direita do que à esquerda em relação à ordenada máxima, ou coeficiente de assimetria positivo.

Por outro lado, se o prolongamento for maior na esquerda, ou coeficiente de assimetria negativo, tem-se uma assimetria à esquerda ou negativa. Uma curva normal possui coeficiente

de assimetria igual a zero. Na Fig. 2.4 tem-se a representação gráfica das três formas de assimetrias supracitadas.

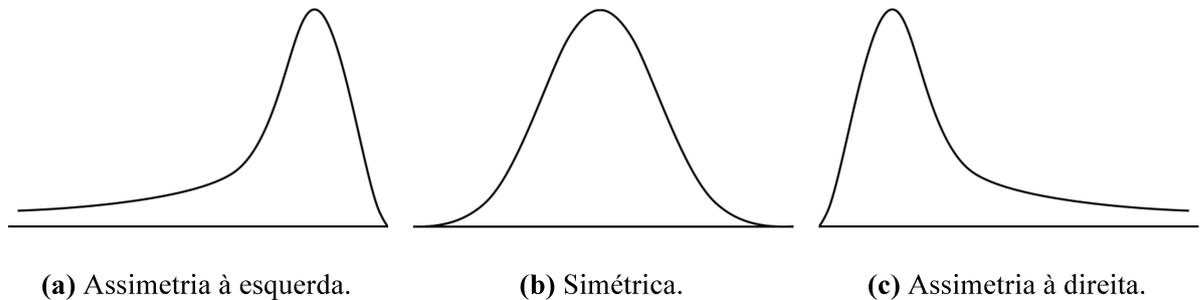


Figura 2.4 - Tipos de assimetria. Fonte: Autor (2018).

O coeficiente de assimetria, com base no momento centrada na média de terceira ordem, é calculado de acordo com Eq. 2.2, onde n é o tamanho da população, x_i é o valor da amostra, \bar{x} é a média amostral, σ o desvio padrão amostral.

$$Sk = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\sigma^3} \quad (2.2)$$

2.4.3. Curtose (Kurtosis)

A Curtose tem como objetivo caracterizar a forma da distribuição em relação a seu achatamento. O termo médio de comparação é dado pela Distribuição Normal. Em relação ao achatamento da distribuição, a mesma pode ser classificada em: Platicúrticas, Mesocúrticas e Leptocúrticas, Fig. 2.5.

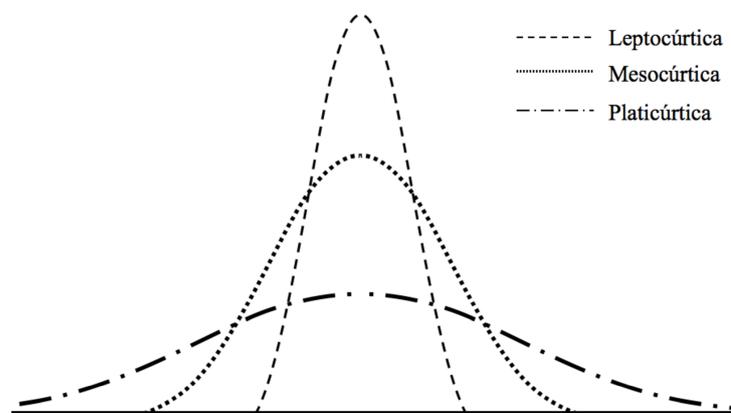


Figura 2.5 - Tipos de achatamento da Distribuição Normal. Fonte: Autor (2018).

Para definição do tipo de achatamento calcula-se o coeficiente de curtose através da Eq. 2.3, onde n é o tamanho da população, x_i é o valor da amostra, \bar{x} é a média amostral e σ é o desvio padrão amostral. Se o coeficiente de curtose for menor que 3 a distribuição é classificada como Platicúrticas. Se for igual a 3 tem-se uma distribuição Mesocúrticas. Para valores maiores que 3 denomina-se Leptocúrticas.

$$a_4 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\sigma^4} \quad (2.3)$$

2.4.4. Valor médio quadrático (RMS)

Considerado umas das medidas mais importantes na análise do domínio do tempo é o valor médio quadrático (**RMS**), Fig. 2.6.

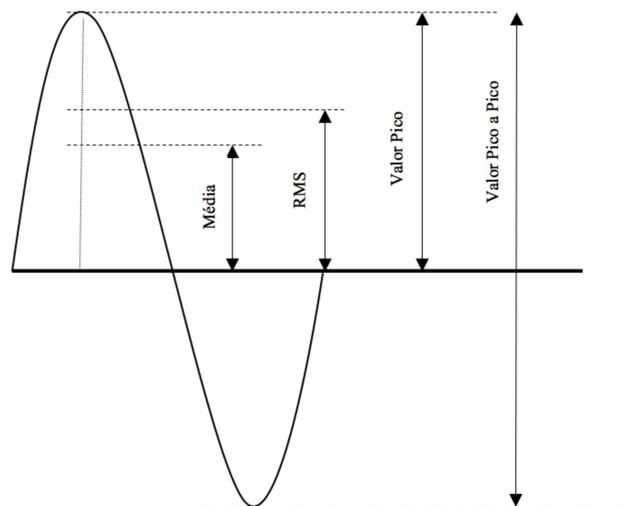


Figura 2.6 - Medidas de amplitude. Fonte: Autor (2018).

O **RMS** leva em consideração tanto a cronologia da onda como também o valor de amplitude diretamente ligado à energia contida na mesma, calculado de acordo com Eq. 2.1, onde $x(t)$ é a função que define o sinal no domínio do tempo e T o período.

$$RMS = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt} \quad (2.4)$$

2.4.5. Valor pico

O valor de pico é o valor da maior amplitude presente no sinal medida a partir do valor zero, o qual não leva em conta a cronologia da onda. Por ser um valor pontual é muito utilizado para verificar presença de choques mecânicos no sistema. A representação de sua medida pode ser vista na Fig. 2.6.

2.4.6. Valor pico a pico

Diferente do valor de pico, o valor pico a pico representa a excursão máxima da onda, ou seja, é a da diferença entre o pico e o vale no sinal. A representação de sua medida também pode ser vista na Fig. 2.6.

2.4.7. Fator de crista

O fator de crista, calculado de acordo com Eq. 2.5, indica a presença de ocorrências fora da normalidade, informando assim o quão homogêneo é o sinal.

$$Fc = \frac{\text{Valor pico}}{\text{Valor RMS}} \quad (2.5)$$

2.4.8. Fator K4

De acordo com Vanzo (2017) e Reis (2017), o parâmetro K4, calculado de acordo com Eq. 2.6, apresenta-se como um indicador de falhas e para verificação de anormalidade em equipamentos, componentes e processos.

$$K4 = (RMS \cdot \text{Curtose}) \quad (2.6)$$

2.5. Parâmetros vibratórios no domínio da frequência

Em geral, a análise no domínio do tempo não permite a correta identificação, diagnóstico e localização da falha. Por esse motivo, diversos pesquisadores utilizam a análise do sinal no domínio da frequência. A função densidade espectral de potência fornece maiores informações a cerca do problema em estudo.

Atualmente uma das técnicas mais utilizadas para calcular um espectro de potência envolve o uso da Transformada Rápida de Fourier (FFT - Fast Fourier Transform), para converter o sinal de uma amostra discreta e finita, que se encontra no domínio do tempo para o domínio da frequência. O algoritmo FFT possui menor complexidade computacional quando comparado com a Transformada Discreta de Fourier (DFT - *Discrete Fourier Transform*), sendo um dos motivos de sua ampla utilização e aplicação nesse estudo.

Dessa forma, dado um sinal no domínio da frequência diversos parâmetros podem ser extraídos para tentar identificar a condição de desgaste da ferramenta, os quais são apresentados a seguir.

Tendo em vista a grande dificuldade de correlacionar as variações do sinal de vibração no processo de torneamento com o desgaste, propõe-se a divisão do mesmo em diversas bandas de frequências a fim de identificar a região do espectro que apresenta maior correlação com a condição de vida da ferramenta, ou seja, com o desgaste.

2.5.1. Nível de energia do sinal filtrado em bandas de frequência

Pode-se obter o nível de energia RMS do sinal filtrado nas respectivas bandas de frequência em função do desvio padrão. Segundo Lima (2004), o valor RMS, em função do desvio, tem uma melhor representatividade das verdadeiras flutuações que, em geral, ocorrem nas amostras típicas e, por causa disso, é mais frequentemente utilizado em cálculos estatísticos. Seu valor pode ser calculado de acordo com Eq. 2.7, onde n é o tamanho da amostra, x_i o valor da amostra e \bar{x} a média amostral.

$$S_{rms} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n |x_i - \bar{x}|^2} \quad (2.7)$$

2.5.2. Nível de energia do envelope sinal filtrado em bandas de frequência

Conforme mostrado por Randal (2011), outra técnica amplamente utilizada para análises de sinais é a Técnica de Envelope, obtido através da Transformada de Hilbert, Fig. 2.7.

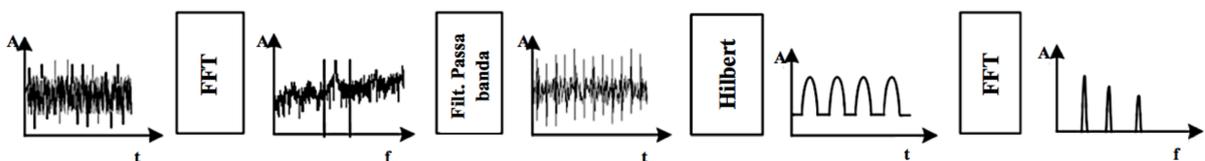


Figura 2.7 - Análise de envelope utilizando a Transformada de Hilbert. Fonte: Adaptado de Bezerra (2004).

Conforme mostrado na Fig. 2.7, a técnica pode ser dividida em cinco partes. Primeiramente aplica-se a FFT ao sinal no domínio tempo, com objetivo de definir a faixa de filtragem. Em seguida, aplica-se um filtro de passa banda, na faixa de interesse, a fim de eliminar baixas frequências de altas amplitudes. Posteriormente aplica-se a transformada de Hilbert que é um processo de demodulação com o objetivo de obter o envelope do sinal. Por fim, aplica-se a FFT ao envelope do sinal a fim de obter as frequências de interesse.

Novamente, devido à dificuldade de associar frequências determinísticas ao desgaste da ferramenta, nessa dissertação calculou-se os parâmetros vibratórios para a Técnica de Envelope, conforme sugerido por Duarte (2005 *apud* Duarte, 2013). Ou seja, calculou-se o nível de energia média quadrática e a razão entre os valores máximos e mínimos do módulo das bandas selecionadas do sinal analítico obtido através da Técnica de Envelope.

2.6. Técnicas estatísticas

Tão importante quanto a determinação dos parâmetros vibratórios a ser estudados é a seleção dos mesmos. Utilizar os melhores parâmetros e a quantidade correta são fatores fundamentais para o sucesso do método.

Atualmente existem diversas técnicas para avaliação dos parâmetros das quais selecionou-se: Teste F-Snedecor para verificação da homocedasticidade da população e, conseqüente, definição do tipo de Teste-t de comparação das médias populacionais a ser usado. O Teste de Chauvenet para verificação de valores extremos e o Gráfico Boxplot para validação dos resultados obtidos através do Teste-t.

2.6.1. Teste de homocedasticidade: Teste F-Snedecor

Tendo em vista o objetivo de comparar o valor médio de duas populações (para o caso em estudo, ferramentas em boas condições de uso e desgastadas) utiliza-se o Teste F-Snedecor a fim de verificar a homocedasticidade da população e, conseqüentemente, definir qual o teste de hipótese sobre igualdade de populações a ser utilizado.

Amplamente utilizado em diversas pesquisas desde a área médica a aplicações na engenharia, segundo Cárach *et al.* (2018), o teste calcula o valor da estatística **F**, de acordo com Eq. 2.8, onde **s** é o desvio padrão de cada amostra respectivamente.

$$F_o = \frac{s_1^2}{s_2^2} \quad (2.8)$$

Duas hipóteses básicas acerca do desvio padrão são formuladas, sendo $\mathbf{H}_0: \sigma_1 = \sigma_2$ e $\mathbf{H}_1: \sigma_1 \neq \sigma_2$. Utilizando uma alternativa bilateral, tem-se que a hipótese nula (\mathbf{H}_0) será rejeitada com nível de significância (α) de 5%, se Eq. 2.9 for válida.

$$F_o > F_{1-\frac{\alpha}{2}, n_1-1, n_2-1} \text{ ou } F_o < F_{\frac{\alpha}{2}, n_1-1, n_2-1} \quad (2.9)$$

2.6.2. Teste de comparação das médias populacionais: Teste-t

O Teste-t fornece informações relevantes em relação a diferença das médias populacionais. Dessa forma é possível utilizá-lo para selecionar os parâmetros que apresentam diferenças, ou seja, bons classificadores para determinar se a ferramenta está em boas condições de uso ou desgastada.

O teste calcula o valor da estatística t , de acordo com Eq. 2.10, para população heterocedástica com g graus de liberdade, onde \bar{x}_1 e \bar{x}_2 são as médias amostrais; μ_1 e μ_2 são as médias populacionais; s_1 e s_2 são os valores dos desvios padrões das amostras e n_1 e n_2 são o tamanho das amostras. O valor de g é calculado pela Eq. 2.11. A população homocedástica (t_{homo}), com $(n_1 + n_2 - 2)$ graus de liberdade, é calculado através da Eq. 2.12.

$$t_{hetero} = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (2.10)$$

$$g = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}\right)^2}{\frac{\left(\frac{s_1^2}{n_1}\right)^2}{n_1 + 1} + \frac{\left(\frac{s_2^2}{n_2}\right)^2}{n_2 + 1}} - 1 \quad (2.11)$$

$$t_{homo} = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (2.12)$$

Para o Teste t, duas hipóteses básicas acerca da média foram formuladas sendo $H_0: \mu_1 = \mu_2$ e $H_1: \mu_1 \neq \mu_2$. Utilizando uma alternativa unilateral à direita, tem-se que a hipótese nula (H_0) será rejeitada com nível de significância (α) de 5%, se Eq. 2.13 for válida.

$$t > t_{\text{crítico}} \quad (2.13)$$

2.6.3. Gráfico *Boxplot*

O Gráfico *Boxplot*, Fig. 2.8, também conhecido como Diagrama de Caixas (*Boxplot*), é utilizado para avaliar visualmente a distribuição dos dados e comparar dois ou mais grupos.

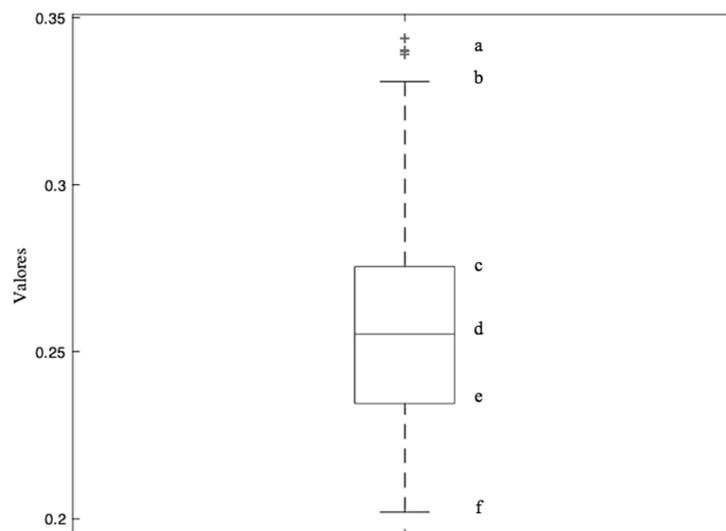


Figura 2.8 - Exemplo de Gráfico *Boxplot*. Fonte: Autor (2018).

Conforme pode ser visto na Fig. 2.8, o gráfico é composto pelo primeiro e terceiro quartil, sendo o primeiro quartil representado pela linha inferior (**e**), onde 25% dos dados encontram-se abaixo da mesma e o terceiro quartil representado pela linha superior (**c**), onde 25% dos dados encontram-se acima da mesma. Além dos quartis supracitados, tem-se o a mediana (**d**), também conhecida como segundo quartil.

De acordo com Duarte (2013), a haste superior (**b**) indica o valor mínimo de dados que é maior que o primeiro quartil menos 1,5 vezes o comprimento do interquartil (diferença entre os valores do terceiro quartil e o primeiro quartil). Já a haste inferior (**f**) indica o valor máximo

dos dados que é menor que o terceiro quartil mais uma constante vezes o comprimento do interquartil.

Os pontos fora dos limites superior e inferior (**a**) são considerados *outliers*, ou também chamados de valores discrepantes.

Segundo Duarte (2013), algumas informações estatísticas podem ser inferidas pela análise do gráfico conforme apresentado a seguir.

- Uma grande qualidade da mediana, em relação à média, reside no fato de que a mesma é menos sensível a valores extremos, o que é muito útil em análise que envolve dados com grandes dispersões.
- A distância entre as linhas do primeiro e terceiro quartil e a mediana dá uma ideia sobre o nível de achatamento da distribuição.
- A diferença entre os comprimentos das caixas superior e inferior é um indicativo da assimetria da distribuição.
- A distância entre as hastes superior e inferior e a mediana é um indicativo das "excursões fora da média" do grupo de dados.

2.6.4. Teste de valor extremo: Critério de Chauvenet

Em um teste experimental é comum a presença de valores extremos que extrapolem a tendência dominante. Esses valores podem representar fenômenos de interesse do pesquisador, ou também erros de medição. Por isso, torna-se necessário utilizar um critério para definir sobre a eliminação ou não desse valor.

Existem diversos critérios para testar valores extremos. Em todos eles, calcula-se um valor estatístico da amostra e compara-se a um valor crítico baseado na teoria do teste. Um dos métodos mais utilizados é o Critério de Chauvenet.

Para aplicar o Critério de Chauvenet deve-se calcular r de acordo com a Eq. 2.14, onde x_i é o valor da amostra, \bar{x} é a média amostral e σ é o desvio padrão amostral.

$$r = \frac{|x_i - \bar{x}|}{\sigma} \quad (2.14)$$

Após calculado o valor r deve-se verificar se o mesmo é maior que o R_c estabelecido pelo Critério de Chauvenet, Tab. 2.1. Se o valor de r for maior que R_c a amostra deve ser excluída.

Tabela 2.1 - Valores críticos Rc.

Número de leituras	Valor Crítico (Rc)
2	1,15
3	1,38
4	1,54
5	1,65
6	1,73
7	1,80
10	1,96
15	2,13
25	2,33
50	2,57
100	2,81
1 000	3,48

Fonte: Adaptado Chauvenet (1960).

2.7. Técnicas de inteligência artificial

Conforme apresentado no Capítulo I, nos últimos anos, diversos pesquisadores têm aplicado Técnicas de Inteligência Artificial para monitoramento e detecção da condição de desgaste da ferramenta.

Para o desenvolvimento de uma ferramenta de classificação é fundamental criar um sistema que seja capaz de identificar se o processo ainda se encontra dentro dos padrões especificados ou se está na hora de intervir, que, no caso em estudo, significa trocar a ferramenta.

Uma das formas de criar esse sistema é através do aprendizado supervisionado. Ou seja, através de exemplos, entradas e saídas conhecidas e definidas, aprende-se uma função que irá caracterizar a saída em relação à entrada. Posteriormente, o usuário deve validar a resposta do sistema e, caso necessário, realizar um novo treinamento a fim de corrigir os pesos utilizados, minimizando assim o erro obtido anteriormente.

Destaca-se a importância de estudar corretamente o modelo para que o mesmo não tenha a presença de fenômenos tais como "Sobreajuste" (do inglês: *Overfitting*) e "Ajuste Inadequado" (do inglês: *Underfitting*). Ou seja, quando se tem um erro baixo sobre os exemplos

de aprendizagem, porém um erro elevado para o conjunto de teste (*Overfitting*), ou ainda, quando já se tem um erro elevado na aprendizagem (*Underfitting*).

Singh, Thakur, Sharma (2016) apresentam uma revisão sobre os principais métodos supervisionados de classificação de dados através de Técnicas de Inteligência Artificial, dos quais se destacam: Árvores de Decisão, k-Vizinho Mais Próximo (*kNN* do inglês: *k-Nearest Neighbor*), Máquina de Vetores de Suporte (SVM, do inglês: *Support Vector Machines*), Rede Bayesiana, Regressão Logística e Redes Neurais. Tendo em vista a especificidade de cada método em relação a sua aplicação, para este trabalho, optou-se por testar as variações das seguintes técnicas: *kNN* (*k-Nearest Neighbor*), SVM (*Support Vector Machines*) e Redes Neurais.

2.7.1. *W-kNN (Weighted k-Nearest Neighbor)*

A primeira contribuição para o desenvolvimento da regra presente no método de análise através dos k-vizinhos mais próximos (*k-Nearest Neighbor*) foi realizada por Fix e Hodges (1951), os quais investigaram uma forma de determinar a classificação de uma amostra baseado nas amostras vizinhas advindas de um conjunto de treinamento.

Dando sequência aos estudos, Cover e Hart (1967) estudaram extensivamente a técnica e suas propriedades aplicada ao reconhecimento de padrões, mostrando que, mesmo com as limitações computacionais da época, o método apresenta bons resultados.

Posteriormente, Dudani (1976), propôs uma nova abordagem do método, denominada *W-kNN (Weighted k-Nearest Neighbor)*, utilizada nesse trabalho. A nova regra passou a atribuir pesos para os vizinhos mais próximos. Ou seja, os vizinhos que se encontravam mais próximos da amostra a ser classificadas recebiam um peso maior do que aqueles que se encontravam mais distantes. O fator peso pode ser calculado através do inverso do quadrado da distância euclidiana, de acordo com Eq. 2.15, sendo d_i a distância euclidiana da amostra até o ponto o vizinho avaliado.

$$w_i = \frac{1}{d_i^2} \frac{1}{\sum_{i=1}^k \frac{1}{d_i^2}} \quad (2.15)$$

Em linhas gerais, o método consiste em calcular o fator peso e a distância da amostra que se deseja classificar, em relação a um conjunto de amostras previamente treinadas. A variável

k é definida pelo usuário e representa a quantidade de vizinhos mais próximos que o método irá utilizar para classificar a amostra, conforme mostrado na Fig. 2.9, sendo Rótulo I as variáveis pertencentes a um grupo e Rótulo II as variáveis pertencentes ao outro grupo.

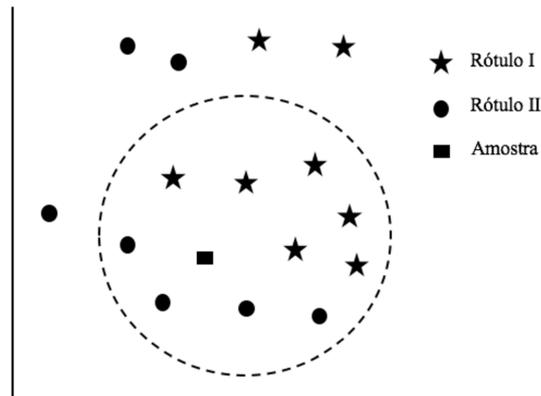


Figura 2.9 - Exemplo de classificação do kNN com dois rótulos de classe e $k=10$. Fonte: Autor.

Para utilização do método, os dois fatores supracitados devem ser definidos, sendo eles: a métrica de distância entre as amostras e a quantidade de vizinhos. A métrica mais utilizada é a distância Euclidiana, a qual está representada na Eq. 2.16, onde \mathbf{p} e \mathbf{q} são pontos n -dimensionais, que representam as amostras utilizadas para classificação e a nova amostra a ser testada.

$$d = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2.16)$$

Conforme mostrado por Wu, Yang e Wang (2018), em geral, o método W-kNN apresenta melhores resultados comparado ao método tradicional kNN. Dessa forma, os vizinhos mais próximos da nova amostra são mais similares e, devido a menor distância, recebem maior peso do que aquelas que também são utilizadas para classificar a nova amostra, porém encontram-se mais distantes.

2.7.2. SVM (Support Vector Machines)

A partir dos estudos iniciados por Vapnik e Chervonenkis (1971), Vapnik (1995) desenvolveu o método conhecido por Máquinas de Vetores de Suporte (SVM, do inglês *Support*

Vector Machines), fundamentada pela teoria do aprendizado estatístico. Além disso, a formulação utilizada no modelo SVM baseia-se no princípio de Minimização do Risco Estrutural (SRM, do inglês *Structural Risk Minimization*), que comparado ao princípio de Minimização do Risco Empírico (ERM, do inglês *Empirical Risk Minimization*) utilizado em redes neurais, tem um desempenho de generalização superior, Vapnik, Golowich e Smola (1996).

Segundo Silva (2012) o princípio Minimização do Risco Empírico não leva em consideração a complexidade das funções indicadoras. Quando a complexidade das funções é superior à necessidade do problema, ocorre o sobreajuste da função ao conjunto de treinamento. Quando ela é inferior, ocorre o subajuste. Em ambos os casos, a capacidade de generalização é reduzida.

Visando solucionar esse problema, o princípio de Minimização do Risco Estrutural utiliza uma dimensão, denominada VC (Vapnik-Chervonenkis), para controlar a complexidade das funções indicadoras, de forma a adequá-las a cada problema, Silva (2012).

As SVMs, em geral, apresentam algumas características que vem tornando o seu uso bastante atrativo, podendo destacar: boa capacidade de generalização, robustez para grandes dimensões, teoria bem definida e convexidade da função objetivo.

O funcionamento de uma SVM pode ser explicado conforme apresentado a seguir. Ou seja, dadas duas classes e um conjunto de pontos que pertencem a essas classes, uma SVM determina o hiperplano que separa os pontos de forma a colocar o maior número de pontos da mesma classe do mesmo lado, enquanto maximiza a distância de cada classe a esse hiperplano. A distância de uma classe a um hiperplano é a menor distância entre ele e os pontos dessa classe e é chamada de margem de separação. O hiperplano gerado pela SVM é determinado por um subconjunto dos pontos das duas classes, chamado vetores suporte, Chaves (2006).

Para poder trabalhar com superfícies não lineares as SVMs utilizam funções Kernel. Elas transformam, os dados de entrada em um espaço de maior dimensão denominado espaço de características, onde pode-se realizar uma separação linear. Algumas das funções Kernel mais utilizadas são: linear, polinomial, gaussiano e sigmoidal.

Pode-se dizer que usar um Kernel normalmente significa usar uma função de classe maior, aumentando assim a capacidade de aprendizado da máquina e a capacidade em separar linearmente problemas que no início não eram possíveis, Silva (2012).

Na Fig. 2.10. tem-se a representação gráfica da explicação supracitada, sendo x_1 e x_2 dois pontos dentro do hiperplano, H_1 e H_2 hiperplanos e Y a distância entre o hiperplano e hiperplano de separação $(w, x) + b = 0$.

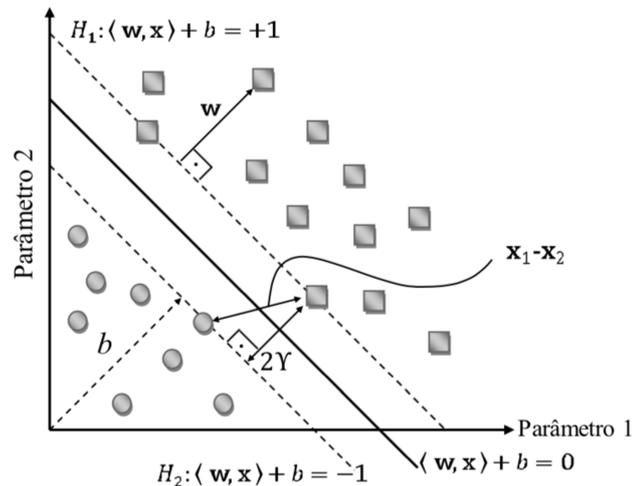


Figura 2.10 - Cálculo da distância entre os hiperplanos. Fonte: Silva (2012).

2.7.3. Rede Neural SOM (Self organizing map)

Os mapas auto-organizáveis (SOM, do inglês *Self Organized Maps*) também conhecido como Redes de Kohonen, ou redes competitivas, foram propostos por Kohonen, (1981). Diferente dos dois métodos de Inteligência Artificial apresentados anteriormente, a rede SOM possui aprendizado não supervisionado. Ou seja, dado um conjunto de valores, a rede busca informações que possam gerar padrões parecidos a fim de classificar os dados em grupos diferentes.

A arquitetura do SOM corresponde a uma rede neural com uma camada competitiva bidimensional ou unidimensional, onde existe interação lateral entre os neurônios dentro de uma vizinhança. Elas combinam competição com uma forma de aprendizagem objetivando o melhor ajuste de seus pesos.

O funcionamento da rede pode ser resumido da seguinte forma. Inicialmente inicia-se os pesos com valores aleatórios pequenos, conforme sugerido por Kohonen (1982). Em seguida, o conjunto de entrada é apresentado. Posteriormente calcula-se a similaridade, e o neurônio vencedor é definido como vizinhança topológica. Os pesos são novamente atualizados e o processo se repete até convergência final determinada.

Segundo Affonso (2011), a rede SOM é caracterizado pela formação de um mapa topográfico dos padrões de entrada, no qual as localizações espaciais (ou coordenadas) dos neurônios na treliça são indicativas de características estatísticas (implícitas) contidas nos padrões de entrada.

CAPÍTULO III

METODOLOGIA E PROCEDIMENTO EXPERIMENTAL

Neste capítulo apresenta-se a metodologia utilizada para coletar e analisar os sinais de vibração com o objetivo de determinar a condição de desgaste da ferramenta. Na Fig. 3.1 tem-se o fluxograma do resumo da metodologia.

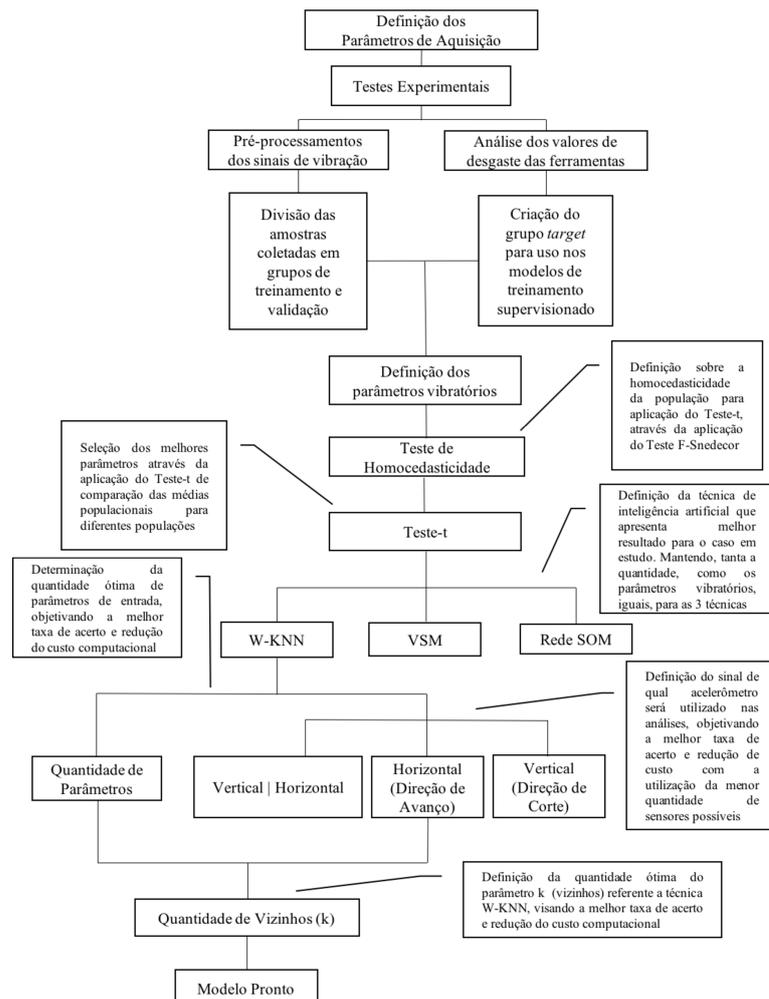


Figura 3.1 - Fluxograma do resumo da metodologia. Fonte: Autor (2018).

Na Fig. 3.2 tem-se o esquema geral com os equipamentos utilizados nos testes, os quais serão detalhados neste capítulo. (1) representa a peça usinada, (2) acelerômetro posição horizontal, (3) acelerômetro posição vertical, (4) ferramenta de corte, (5) suporte da ferramenta, (6) contra ponta, (7) amplificador de carga, (8) placa de aquisição e (9) computador.

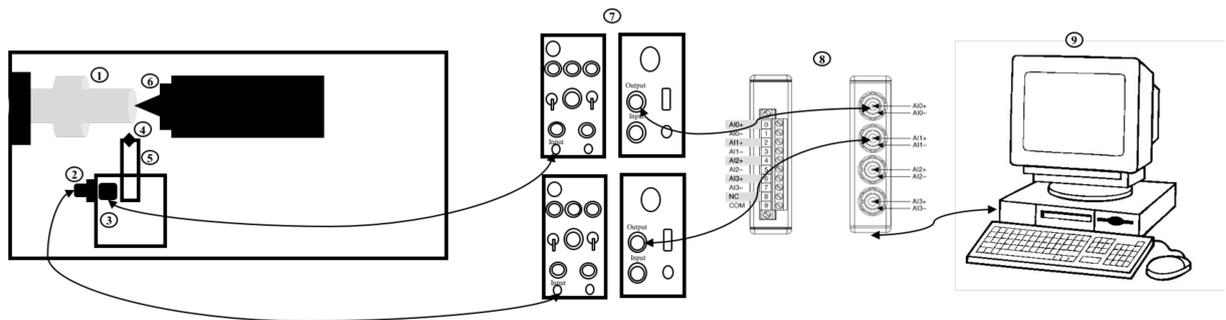


Figura 3.2 - Esquema de montagem dos equipamentos. Fonte: Autor (2018).

A seguir apresenta-se a sequência dos testes.

- i) Montagem do aparato de teste no torno CNC.
- ii) Referenciamento do centro de usinagem.
- iii) Verificação e calibração dos sensores de vibração.

Após conclusão das etapas supracitadas, iniciou-se o processo de usinagem. A cada passe realizado mediu-se o desgaste da ferramenta, e coletou-se os sinais de vibração.

Os dados coletados foram analisados utilizando Técnicas de Estatísticas Clássicas e Técnicas de Inteligência Artificial, e a rotina computacional apresentada no Anexo I. Também realizou-se o estudo da influência da variação dos parâmetros das Técnicas de Inteligência Artificial selecionado na taxa de acerto final, assim como a influência dos parâmetros de entrada e da posição do sensor.

3.1. Bancada experimental

Os testes foram realizados em um torno CNC ROMI Multiplic-35D, com 11 kW de potência no motor principal e rotação máxima de 3 000 rpm, Fig. 3.3. Utilizou-se uma rotina previamente determinada, Apêndice I, para realização dos procedimentos de usinagem.



Figura 3.3 - Torno CNC ROMI Multiplic-35D. Fonte: Autor (2018).

Na Tab. 3.1 tem-se a descrição do material da peça utilizada no trabalho e suas respectivas características. Na Fig. 3.4 tem-se a foto da peça usinada.

Tabela 3.1 - Material da peça utilizado e suas respectivas características.

Material da peça	Composição química (%)				Dureza
	C	Cr	W	V	
VC131 (ABNT D6)	2,1	11,5	0,7	0,1	58 HRC

Fonte: Autor (2018).

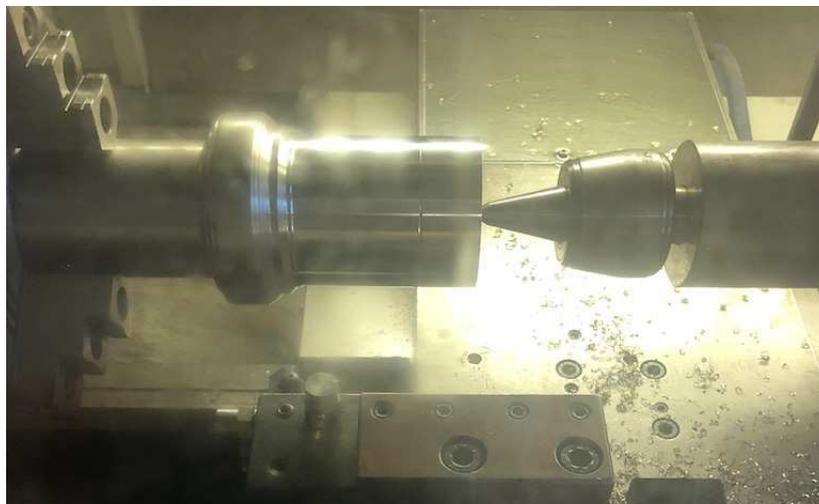


Figura 3.4 - Peça usinada. Fonte: Autor (2018).

Na Tab. 3.2 tem-se os parâmetros de corte selecionados. Para o caso em estudo, selecionou-se uma velocidade de corte de tal forma a evitar a formação da aresta postiça de corte. Tendo em vista, que com o aumento da velocidade de corte, a temperatura de corte também se eleva, ultrapassando assim a temperatura de recristalização do cavaco e, conseqüentemente, evitando a formação da aresta postiça de corte, Diniz; Marcondes; Coppini (2013). Além disso, os parâmetros de corte selecionados, foram definidos para obter uma pequena variação no desgaste medido VB_{Bmax} a cada passe, possibilitando assim correlacionar os sinais de vibração coletados com o desgaste da ferramenta.

Tabela 3.2 - Parâmetros de corte.

v_c (velocidade de corte)	a_p (profundidade de corte)	f (avanço)
200 m / min	0,2 mm	0,1mm / rot

Fonte: Autor (2018).

Utilizou-se a ferramentas classe MBC 020, Fig. 3.5, do fabricante Mitsubishi com 4 aristas cada, CBN (nitreto cúbico de boro) com cobertura, identificação NP-SNGN090308GA4.

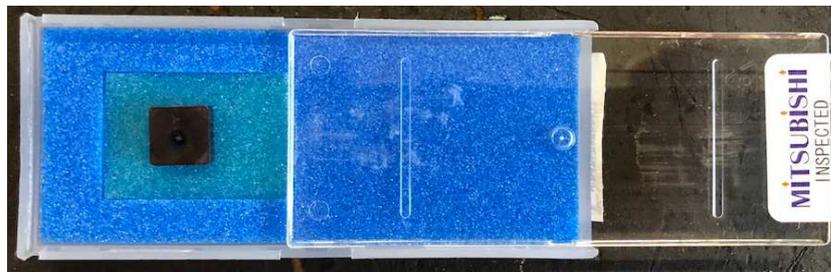


Figura 3.5 - Ferramenta de corte utilizada. Fonte: Autor (2018).

Na Fig. 3.6 tem-se a foto do porta ferramenta do tipo CSSNR-2020-K09 utilizado para fixação da ferramenta.



Figura 3.6 - Porta ferramenta. Fonte: Autor (2018).

Para coleta dos dados utilizou-se dois acelerômetros piezoelétricos Brüel & Kjær, fixados no suporte da ferramenta através de uma cola específica, nas posições vertical (direção de corte) e horizontal (direção de avanço), conforme mostrado na Fig. 3.7, com as dimensões em mm. Para definição da posição de fixação dos sensores, utilizou-se como base as considerações a cerca da análise modal operacional desenvolvida por Meola (2009). Na Tab. 3.3 tem-se as especificações dos acelerômetros.

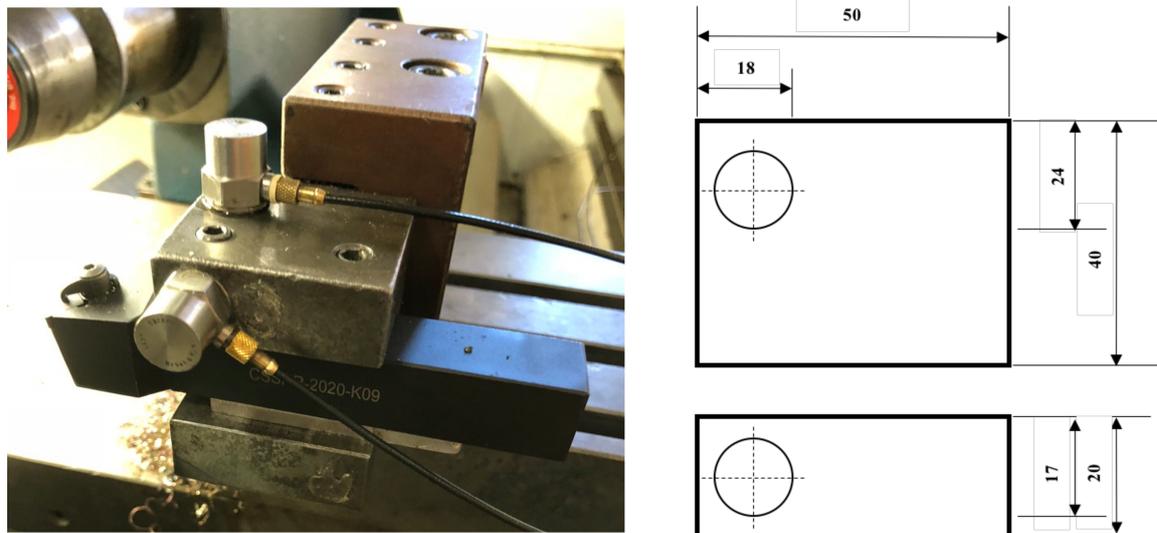


Figura 3.7 - Posição dos acelerômetros. Fonte: Autor (2018).

Tabela 3.3 - Especificação dos acelerômetros.

Acelerômetro Série	Posição	Sensibilidade ($\mu\text{C}/\text{m}/\text{s}^2$)
Brüel & Kjær - 932603	Vertical	1,92
Brüel & Kjær - 932606	Horizontal	2,05

Fonte: Autor (2018).

Os acelerômetros foram conectados a dois amplificadores de carga Brüel & Kjær modelo 2635, Fig. 3.8. Utilizou-se um ganho de 10, visando a coleta de um sinal com a menor quantidade de ruído possível e evitando problemas de *overload*, frequência de corte mínima de 2 Hz e máxima de 10 kHz.



Figura 3.8 - Amplificadores de cargas. Fonte: Autor (2018).

Os amplificadores foram conectados a uma placa de aquisição de sinais da National Instruments, modelo NI USB-9162 | 9233, 24 bits, 4 canais e faixa de medição de -5 V a 5 V na entrada, Fig. 3.9. Utilizou-se o Canal 0 para o acelerômetro fixado na vertical e o Canal 01 para o acelerômetro fixado na horizontal.



Figura 3.9 - Placa National Instruments. Fonte: Autor (2018).

O sistema de monitoramento foi acoplado ao microcomputador marca Dell, modelo Optiplex 7010. Através de um programa de monitoramento em tempo real elaborado em linguagem C++ para aquisição e armazenamento dos dados coletados, os sinais de vibração foram salvos para posterior análise no *software* MATLAB®.

Com base nas análises previamente desenvolvidas sobre o sistema, onde-se coletou sinais com frequências de amostragem maiores que a utilizada, verificou-se que com frequência de 32 768 Hz, tempo de coleta de 15 segundos e resolução em frequência (*df*) de 0,0667 Hz, o sinal de vibração abrangeria todas as excitações que poderiam influenciar no desgaste da ferramenta.

Segundo Mikołajczyk *et al.* (2018), situações típicas de desgaste envolvem mais de um tipo de desgaste. Entretanto, do ponto de vista de processo, o desgaste de flanco VB_{Bmax} é o mais importante e também a variável mais utilizada para avaliação da condição da ferramenta, o qual foi utilizado para o estudo neste trabalho.

O desgaste de flanco máximo foi medido ao final de cada passo de usinagem, através da análise da superfície de folga em um estereó microscópio, SZ61 - Olympus, com câmara digital integrada, com ampliação de 40x, Fig. 3.10.



Figura 3.10 - Microscópio SZ61 - Olympus. Fonte: Autor (2018).

Antes de cada medição procedeu-se a calibração do estéreo microscópio por meio de uma escala graduada. A câmera digital integrada é ligada a um computador com o *software* analisador de imagens Image-Pro® Express 5.1.0.12, responsável pela captação, medição do desgaste e armazenamento da imagem selecionada.

Além da medição de desgaste realizadas com o microscópio SZ61, ao final de todos os testes analisou-se as ferramentas através do microscópio eletrônico de varredura TM3 000, Fig. 3.11 com aumentos de 180 e 300x.



Figura 3.11 - Microscópio eletrônico de varredura TM3 000. Fonte: Autor (2018).

3.2. Procedimento experimental

Após a montagem do aparato experimental procedeu-se a realização dos testes. A peça foi dividida em três partes, espaçadas de 32,6 mm, conforme esquema mostrado na Fig. 3.12. O objetivo da divisão é trabalhar com passe menores e assim obter um melhor controle do desgaste da ferramenta. Dessa forma tem-se maior exatidão na análise dos futuros resultados através das Técnicas de Inteligência Artificial. Cada divisão da peça representou um passe da ferramenta de corte e, conseqüentemente, uma amostra do sinal de vibração.

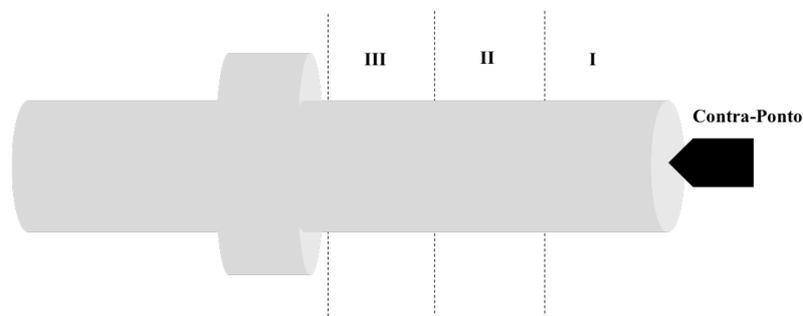


Figura 3.12 - Esquema da divisão da peça a ser usinada. Fonte: Autor (2018).

Para realização dos testes utilizou-se 05 ferramentas e 06 arestas de corte conforme apresentado na Tab. 3.4.

Tabela 3.4 - Identificação das arestas de corte.

Ferramenta	Arresta	Grupo	Nomenclatura Final
F02	A1	01	F02A1
F02	A2	02	F02A2
F03	A1	02	F03A1
F04	A1	02	F04A1
F05	A1	02	F05A1
F06	A1	02	F06A1

Fonte: Autor (2018).

Analisando as curvas de desgaste das ferramentas utilizadas, que serão apresentadas no decorrer deste item, o tipo e tamanho, as condições de usinagem aplicadas, juntamente do tipo de operação praticada por essas ferramentas, no caso, acabamento, e ainda a norma ISO 3685, definiu-se como critério de fim de vida da ferramenta $VB_{Bmax} > 0,35$ mm.

Os testes foram divididos em dois grupos. No primeiro grupo (Grupo I) simulou-se a condição de trabalho mais próxima da praticada na indústria. Dessa forma, utilizou-se apenas uma aresta de uma ferramenta de corte (F02A1) levando-a a valores além do critério de final de vida útil adotado nesse trabalho sem que ocorresse aleatorização ou troca de ferramenta. A F02A1 só era retirada do porta ferramenta para medição do desgaste, retornando a mesma posição no porta ferramenta. Posteriormente utilizou-se o Grupo I para validação dos resultados obtidos pelas Técnica de Inteligência Artificial.

A seguir tem-se as etapas dos testes realizados para o Grupo I.

1. Fixação da ferramenta de corte no porta ferramenta.
2. Verificação do sistema de coleta.
3. Início do processo de usinagem.
4. Início da coleta de sinais após ferramenta começar a usinar.
5. Fim do processo de usinagem e coleta.
6. Retirada de ferramenta do porta ferramenta.
7. Medição do desgaste no microscópio SZ61 - Olympus.
8. Retorno da mesma ferramenta e mesma aresta para o porta ferramenta.
9. Reinício do processo: Item 2.

Na Fig. 3.13 tem-se a curva de desgaste para o Grupo I, utilizando a aresta F02A1. Os valores das medições de desgastes estão disponíveis na Tab. A2.1 (Apêndice II). O desgaste refere-se à medição após o passe realizado. Os sinais de vibração dos testes 07 e 12 nas posições vertical e horizontal foram descartados por apresentarem somente ruídos.

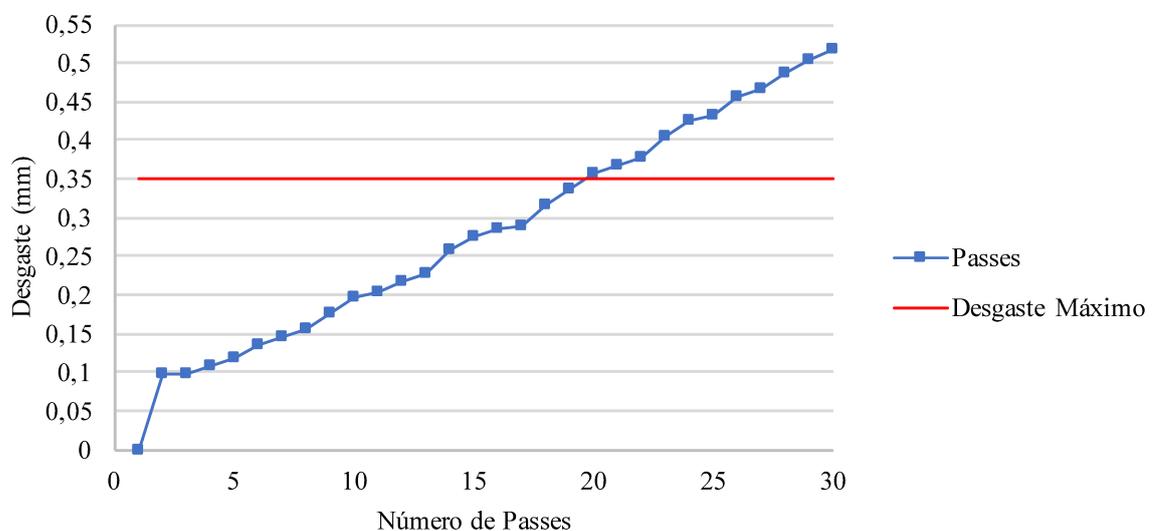


Figura 3.13 - Curva de desgaste de flanco máximo para a aresta F02A1. Fonte: Autor (2018).

Analisando a Fig. 3.13 nota-se um significativo aumento inicial do desgaste (0 - 0.1 mm), como esperado. Posteriormente, e até o final dos testes, o aumento do desgaste foi gradual.

É importante destacar que as curvas de desgaste apresentadas nesse estudo são limitadas a condição de desgaste máximo proposto pelos autores e não pelo fim de vida efetivo (ou quebra) da ferramenta.

Para o segundo grupo (Grupo II) utilizou-se 5 diferentes aristas, sendo uma em cada ferramenta. O objetivo foi construir um conjunto de dados robusto, para posterior utilização no treinamento e teste das Técnica de Inteligência Artificial. Foram realizados 25 testes para cada ferramenta, resultando em um total de 125 testes, os quais foram totalmente aleatorizados.

A seguir tem-se as etapas dos testes realizados para o Grupo II.

1. Fixação da ferramenta de corte no porta ferramenta.
2. Verificação do sistema de coleta.
3. Início do processo de usinagem.
4. Início da coleta de sinais após ferramenta começar a usinar.
5. Fim do processo de usinagem e coleta.
6. Retirada de ferramenta do porta ferramenta.
7. Medição do desgaste no microscópio SZ61 - Olympus.
8. Fixação da próxima ferramenta sorteada aleatoriamente no porta ferramenta.
9. Início do processo novamente no item 2.

Na Fig. 3.14 tem-se a curva de desgaste para o Grupo II, utilizando as arestas F02A2, F03A1, F04A1, F05A1 e F06A1. Os valores das medições de desgastes dos 125 testes estão disponíveis na Tab. A2.2 (Apêndice II). O desgaste refere-se à medição após realizado o passe, assim como a rugosidade da peça.

Os sinais de vibração dos testes 01, 02 e 16, na posição vertical, foram descartados por apresentarem somente ruídos. Na posição horizontal também foram descartados os sinais dos testes 16, 73, 74, 75, 79, 80, 81, 82, 83 e 84.

Analisando a Fig. 3.14 nota-se um comportamento muito similar ao apresentado na Fig. 3.13, como já esperado, uma vez que foi usado o mesmo material, ferramenta e condições de usinagem. Logo, tem-se, inicialmente, um significativo aumento do desgaste. Posteriormente, e até o final dos testes, o aumento do desgaste foi gradual.

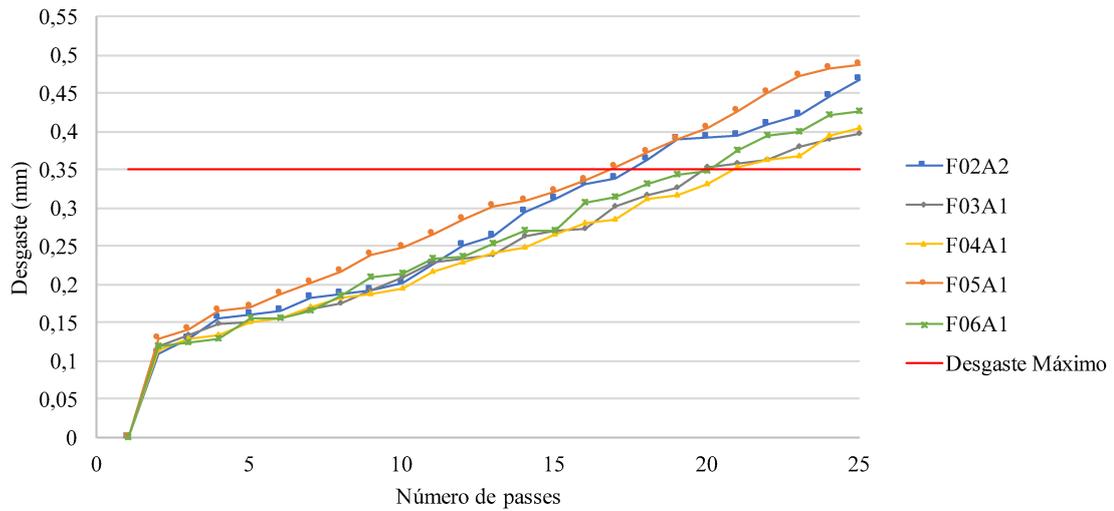


Figura 3.14 - Curva de desgaste para as arestas F02A1, F03A1, F04A1, F05A1 e F06A1. Fonte: Autor (2018).

Na Tab. 3.5 tem-se o resumo dos testes, onde apresenta-se a quantidade de sinais obtidos para cada aresta em relação a ferramenta em boas condições de uso ($VB_{Bmax} \leq 0,35$ mm) e desgastada ($VB_{Bmax} > 0,35$ mm), já excluídos os sinais supracitados.

Tabela 3.5 - Resumo dos testes.

Aresta Ferramenta	Grupo	Quantidade de sinais			
		Posição		Condição da Ferramenta	
		Vertical	Horizontal	Boas Condições de Corte	Desgastada
F02A1	01	17	17	11	11
F02A2	02	17	17	8	8
F03A1	02	19	17	6	6
F04A1	02	20	17	5	5
F05A1	02	14	14	9	8
F06A1	02	19	18	5	5
TOTAL	GRUPO 01	17	17	11	11
SINAIS	GRUPO 02	89	83	33	32

Fonte: Autor (2018).

3.3. Procedimento de análise dos sinais

Uma vez coletados os dados, procedeu-se com análise dos sinais a fim de identificar a condição de desgaste da ferramenta.

Posteriormente foram definidos os parâmetros vibratórios utilizados para identificar a condição de desgaste da ferramenta.

A extração e utilização dos corretos parâmetros vibratórios possibilita a correta identificação do problema e, conseqüentemente, o sucesso do método aplicado. Utilizar parâmetros que não influenciam positivamente no resultado, só contribui para o aumento do custo computacional e redução da assertividade.

A fim de verificar a homocedasticidade da população aplicou-se o Teste F-Snedecor o que possibilita a correta aplicação do Teste *t* de comparação da média populacional.

Finalmente, os melhores parâmetros selecionados através do Teste *t* foram utilizados na análise através das Técnicas de Inteligência Artificial.

3.3.1. Definição dos parâmetros vibratórios

Para identificar a condição de desgaste da ferramenta de corte é necessário, inicialmente, determinar possíveis parâmetros vibratórios que caracterizam o problema em análise. Para o estudo em questão determinou-se 71 parâmetros vibratórios. Dos 71 parâmetros vibratórios calculados, 8 são relacionados ao domínio do tempo, Tab. 3.6.

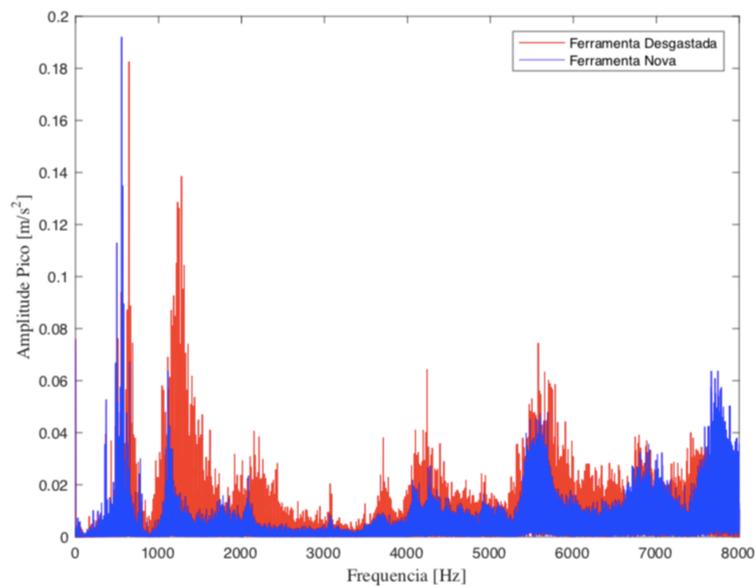
Tabela 3.6 - Sintomas calculados no domínio do tempo.

Sintoma	Descrição
1	Média
2	Assimetria (<i>Skewness</i>)
3	Curtose (<i>Kurtosis</i>)
4	Valor Pico
5	Valor Pico-a-Pico
6	Nível RMS em função da amplitude do sinal
7	Fator de Crista
8	K4 [$10\log_{10}(\text{RMS} * \text{Curtose})$]

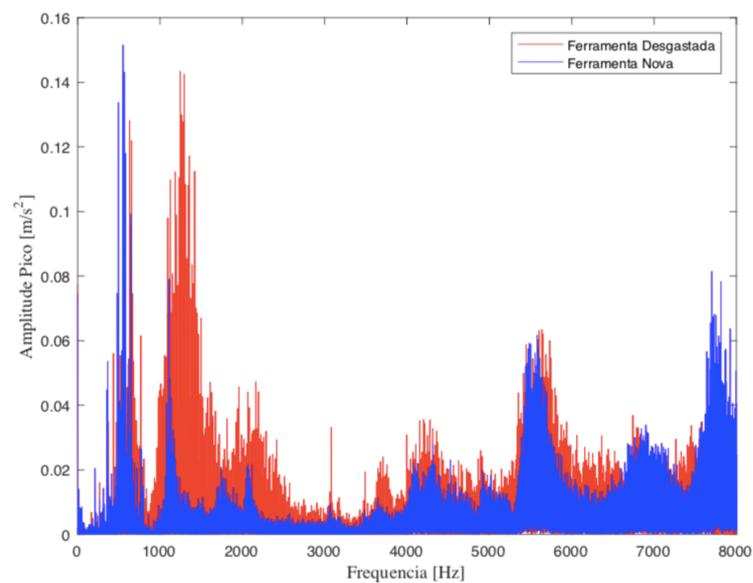
Fonte: Autor (2018).

De acordo com Madhusudana, Kumar, Narendranath (2016) *apud* Vitória (2016), não se pode tirar conclusões definitivas acerca da relação do sinal no tempo com o desgaste da ferramenta. Sendo assim, além dos 8 parâmetros previamente calculados, definiu-se também os parâmetros em função do domínio da frequência.

Para determinação das bandas de frequência que seriam analisadas, realizou-se a FFT do sinal para avaliação. Na Fig. 3.15, tem-se o sinal de vibração no domínio da frequência para as ferramentas F03A1 e F06A1, em boas condições (cor azul) e desgastada (cor vermelha).



(a) Ferramenta F03A1



(b) Ferramenta F06A1

Figura 3.15 - FFT do sinal. Fonte: Autor (2018).

Nota-se que, em geral, a amplitude de vibração aumentou em relação ao desgaste da ferramenta, conforme esperado. Além disso, percebe-se algumas bandas de frequência onde existe uma maior diferença para o sinal entre as ferramentas desgastadas e em boas condições de uso. Essas diferenças em relação as bandas de frequência foram utilizadas para determinação dos parâmetros e estudo de seus comportamentos perante a classificação da ferramenta.

Como não houve diferenças significativas para a posição vertical, na Fig. 3.15 são apresentados somente os sinais na posição horizontal.

Dessa forma, determinou-se 42 parâmetros em função da Análise de Envelope, Tab. 3.7.

Tabela 3.7 - Sintomas calculados relacionados a Análise de Envelope.

Sintoma	Descrição
30	Nível de energia do envelope filtrado com filtro passa baixa em 50 Hz
31	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 50 Hz
32	Nível de energia do envelope filtrado com filtro passa baixa em 100 Hz
33	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 100 Hz
34	Nível de energia do envelope filtrado com filtro passa baixa em 300 Hz
35	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 300 Hz
36	Nível de energia do envelope filtrado com filtro passa baixa em 500 Hz
37	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 500 Hz
38	Nível de energia do envelope filtrado com filtro passa baixa em 1 000 Hz
39	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 1 000 Hz
40	Nível de energia do envelope filtrado com filtro passa baixa em 3 000 Hz
41	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 3 000 Hz
42	Nível de energia do envelope filtrado com filtro passa baixa em 5 000 Hz
43	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 5 000 Hz
44	Nível de energia do envelope filtrado com filtro passa baixa em 7 000 Hz
45	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 7 000 Hz
46	Nível de energia do envelope filtrado com filtro passa baixa em 9 000 Hz

Tabela 3.7 - Sintomas calculados relacionados à Análise de Envelope (Continuação).

Sintoma	Descrição
47	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 9 000 Hz
48	Nível de energia do envelope filtrado com filtro passa baixa em 11 000 Hz
49	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa baixa em 11 000 Hz
50	Nível de energia do envelope filtrado com filtro passa banda entre 5 a 500 Hz
51	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa banda entre 5 a 500 Hz
52	Nível de energia do envelope filtrado com filtro passa banda entre 500 a 3 000 Hz
53	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa banda entre 500 a 3 000 Hz
54	Nível de energia do envelope filtrado com filtro passa banda entre 3 000 a 6 500 Hz
55	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa banda entre 3 000 a 6 500 Hz
56	Nível de energia do envelope filtrado com filtro passa banda entre 6 500 a 10 000 Hz
57	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa banda entre 6 500 a 10 000 Hz
58	Nível de energia do envelope filtrado com filtro passa alta em 500 Hz
59	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 500 Hz
60	Nível de energia do envelope filtrado com filtro passa alta em 1 000 Hz
61	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 1 000 Hz
62	Nível de energia do envelope filtrado com filtro passa alta em 3 000 Hz
63	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 3 000 Hz

Tabela 3.7 - Sintomas calculados relacionados à Análise de Envelope (Continuação).

Sintoma	Descrição
64	Nível de energia do envelope filtrado com filtro passa alta em 5 000 Hz
65	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 5 000 Hz
66	Nível de energia do envelope filtrado com filtro passa alta em 7 000 Hz
67	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 7 000 Hz
68	Nível de energia do envelope filtrado com filtro passa alta em 9 000 Hz
69	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 9 000 Hz
70	Nível de energia do envelope filtrado com filtro passa alta em 11 000 Hz
71	Diferença entre o máximo e mínimo do envelope filtrado com filtro passa alta em 11 000 Hz

Fonte: Autor (2018).

Finalmente, definiu-se 21 parâmetros para bandas de frequências entre 0 a 12500 Hz, Tab. 3.8.

Tabela 3.8 - Sintomas calculados em função de regiões do espectro.

Sintoma	Descrição
9	Nível de energia do sinal filtrado com filtro passa baixa em 50 Hz
10	Nível de energia do sinal filtrado com filtro passa baixa em 100 Hz
11	Nível de energia do sinal filtrado com filtro passa baixa em 300 Hz
12	Nível de energia do sinal filtrado com filtro passa baixa em 500 Hz
13	Nível de energia do sinal filtrado com filtro passa baixa em 1000 Hz
14	Nível de energia do sinal filtrado com filtro passa baixa em 3 000 Hz
15	Nível de energia do sinal filtrado com filtro passa baixa em 5 000 Hz
16	Nível de energia do sinal filtrado com filtro passa baixa em 7 000 Hz
17	Nível de energia do sinal filtrado com filtro passa baixa em 9 000 Hz
18	Nível de energia do sinal filtrado com filtro passa baixa em 11 000 Hz

Tabela 3.8 - Sintomas calculados em função de regiões do espectro (Continuação).

Sintoma	Descrição
19	Nível de energia do sinal filtrado com filtro passa banda entre 5 a 500 Hz
20	Nível de energia do sinal filtrado com filtro passa banda entre 500 a 3 000 Hz
21	Nível de energia do sinal filtrado com filtro passa banda entre 3 000 a 6 500 Hz
22	Nível de energia do sinal filtrado com filtro passa banda entre 6 500 a 10 000 Hz
23	Nível de energia do sinal filtrado com filtro passa alta em 500 Hz
24	Nível de energia do sinal filtrado com filtro passa alta em 1 000 Hz
25	Nível de energia do sinal filtrado com filtro passa alta em 3 000 Hz
26	Nível de energia do sinal filtrado com filtro passa alta em 5 000 Hz
27	Nível de energia do sinal filtrado com filtro passa alta em 7 000 Hz
28	Nível de energia do sinal filtrado com filtro passa alta em 9 000 Hz
29	Nível de energia do sinal filtrado com filtro passa alta em 10 000 Hz

Fonte: Autor (2018).

3.3.2. Análise dos parâmetros vibratórios

Calculados todos os parâmetros vibratórios dos conjuntos das ferramentas em boas condições de uso e desgastadas, buscou-se definir os parâmetros que melhor representam o problema em estudo.

Inicialmente aplicou-se o Teste F-Snedecor a fim de verificar qual o teste de hipótese sobre igualdade de populações deve ser utilizado, testando assim a homocedasticidade.

O Teste F-Snedecor calcula o valor da estatística F, de acordo com Eq. 2.8, apresentada no Capítulo II, aqui repetida para facilitar a dinâmica da leitura. As hipóteses foram testadas para as observações dos Grupos I e II. Na Tab. A3.1, Apêndice III, estão listados os 71 parâmetros estudados e respectivas razões $F/F_{0,975,n_1-1,n_2-1}$ utilizados no teste de homocedasticidade.

$$F_o = \frac{s_1^2}{s_2^2} \quad (2.8)$$

Da análise da Tab. A3.1 determinou-se qual teste de hipótese será aplicado. Parâmetros cuja razão $F/F_{0,975,n_1-1,n_2-1}$ é menor que 1 são considerados amostras homocedásticas. Os

parâmetros que apresentam razão $F/F_{0.975, n_1-1, n_2-1}$ muito maiores que 1, indicam uma grande dispersão dos valores, fato que pode prejudicar a análise quanto a classificação do desgaste da ferramenta.

Após aplicação do Teste F-Snedecor realizou-se o Teste t de comparação de médias amostrais para diferenciação de populações.

O Teste t calcula o valor da estatística t, de acordo com Eq. 2.10, para população heterocedástica com g graus de liberdade, Eq. 2.11 e Eq. 2.12, para população homocedástica, com $(n_1 + n_2 - 2)$ graus de liberdade. Essas equações estão no Capítulo II e aqui repetidas para facilitar a dinâmica da leitura.

$$t_{hetero} = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (2.10)$$

$$g = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}\right)^2}{\frac{\left(\frac{s_1^2}{n_1}\right)^2}{n_1 + 1} + \frac{\left(\frac{s_2^2}{n_2}\right)^2}{n_2 + 1}} - 1 \quad (2.11)$$

$$t_{homo} = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}} \quad (2.12)$$

As hipóteses foram testadas para as observações dos Grupos I e II. Na Tab. A4.1, Apêndice IV, estão listados os 71 parâmetros estudados e respectivas razões $t/t_{0.95, n}$ utilizados no Teste t.

Analisando a Tab. A4 observa-se que os parâmetros cuja a razão $t/t_{0.95, n}$ é maior que 1 são considerados bons sintomas para análise dos sinais em estudo. Ou seja, as médias dos parâmetros para as ferramentas consideradas em boas condições de uso e desgastadas são significativamente diferentes, sendo possível identificar a condição da ferramenta. Além disso, aqueles parâmetros com maiores valores são considerados os melhores.

Levando em consideração que o Grupo I será utilizado apenas para validação dos métodos, realizou-se a seleção dos melhores sintomas com base apenas no Grupo II. Além disso, nota-se que devido a pequena quantidade de dados presente no Grupo I, o mesmo

apresenta menor robustez e valores mais baixos comparados ao Grupo II. Dessa forma, qualquer pequena variação em uma única amostra é capaz de influenciar significativamente todo o conjunto.

Com base em estudos previamente desenvolvidos, e também de acordo com Duarte (2013), notou-se que para as Técnica de Inteligência Artificial utilizadas nesse trabalho, a aplicação de uma grande quantidade de parâmetros de entrada reduz significativamente a taxa de acerto do método. Dessa forma, selecionou-se apenas os 10 melhores parâmetros para o Grupo II, os quais são apresentados na Tab. 3.9. Os mesmos parâmetros serão posteriormente testados a fim de verificar a quantidade exata que resulta em uma maior assertividade para o caso em estudo.

Tabela 3.9 - Seleção dos melhores parâmetros de acordo com o Teste t.

Grupo II					
Posição - Horizontal		Posição - Vertical		Posição - Vertical Horizontal	
Parâmetro	$t/t_{0,95,n}$	Parâmetro	$t/t_{0,95,n}$	Parâmetro	$t/t_{0,95,n}$
52	10,7948	38	9,7214	13	9,3921
40	10,7358	19	9,0105	19	9,2837
13	10,3637	12	8,9925	12	9,2829
20	10,3005	11	8,9711	11	9,0632
12	9,9299	13	8,5835	52	8,9311
19	9,9272	52	8,3516	40	8,6450
11	9,6807	40	8,2414	10	8,4051
38	9,5887	10	7,8304	38	7,7619
14	9,4762	50	7,6796	50	6,8142
42	9,4725	36	7,6737	36	6,8111

Fonte: Autor (2018).

Comparando os valores da Tab. 3.9, nota-se que os parâmetros coletados na posição horizontal apresentaram maiores valores de $t/t_{0,95,n}$. Tal fato é um indicativo que usando apenas um sensor localizado na posição horizontal, a taxa de assertividade para as Técnica de Inteligência Artificial será maior do que usando a posição vertical e a combinação das duas posições. De toda forma, a fim de validar a consideração supracitada, conduziu-se as análises

utilizando todas as combinações presentes na Tab. 3.9 (vertical, horizontal e vertical | horizontal). Os resultados são apresentados no Capítulo IV.

Afim de validar as considerações extraídas através do Teste t de comparação das médias, realizou-se a análise dos Diagramas de Caixa (*Boxplot*) para os parâmetros selecionados.

Na Fig. 3.16 são apresentados os Diagramas de Caixa (*Boxplot*) para os 10 melhores parâmetros referente a posição horizontal para o Grupo II.

Analisando a Fig. 3.16 nota-se que, apesar da presença de *outliers* nas amostras, todas as caixas e medianas dos parâmetros relacionados a ferramenta em boas condições de uso encontram-se abaixo daqueles para as ferramentas desgastadas, conforme proposto por Duarte (2013). Isso se deve ao fato dos níveis de energia das ferramentas em boas condições de uso serem menores do que para uma ferramenta desgastada.

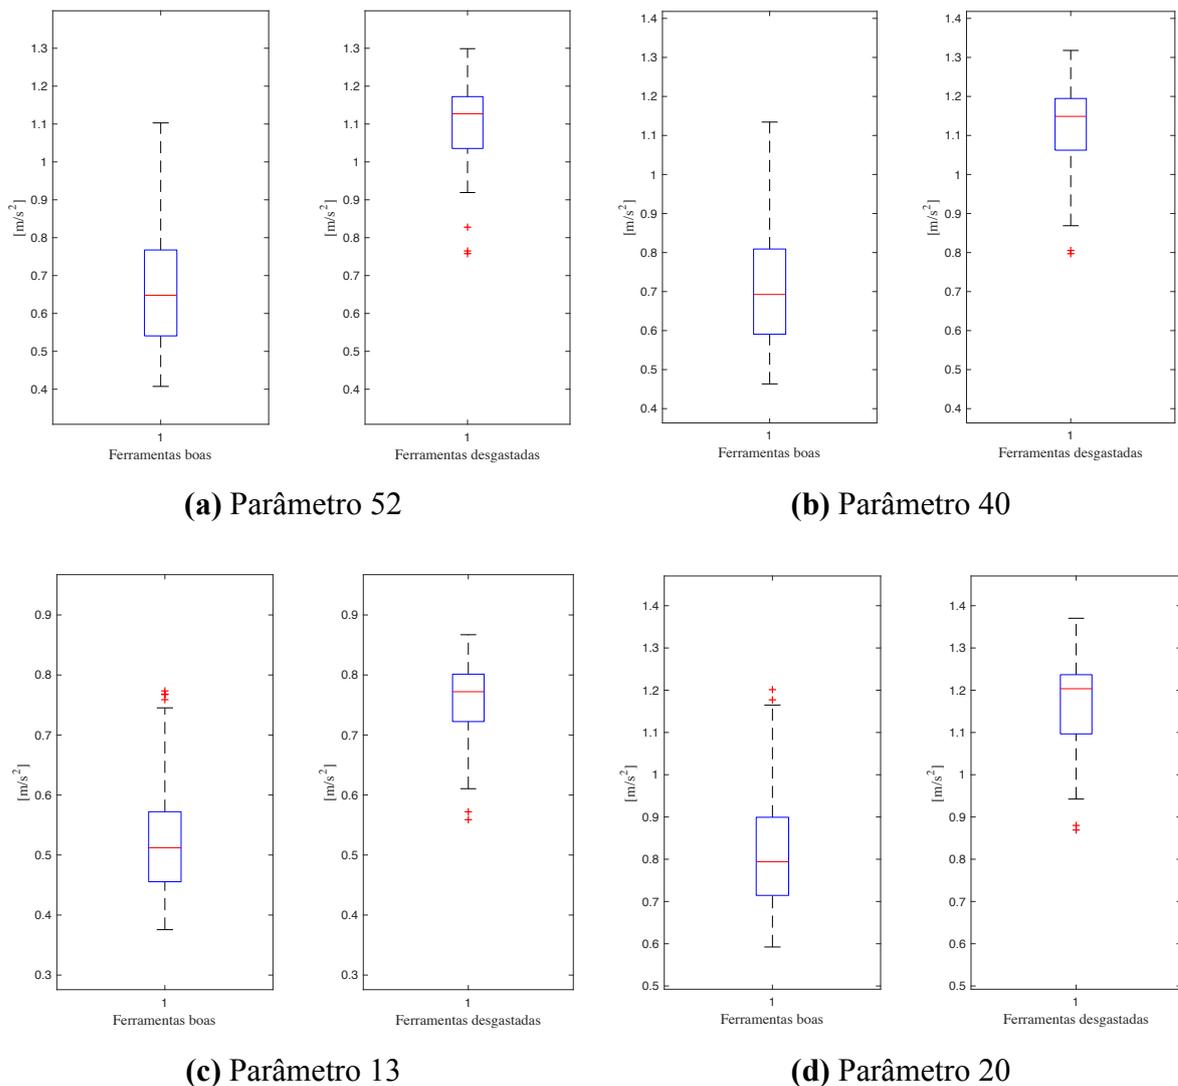
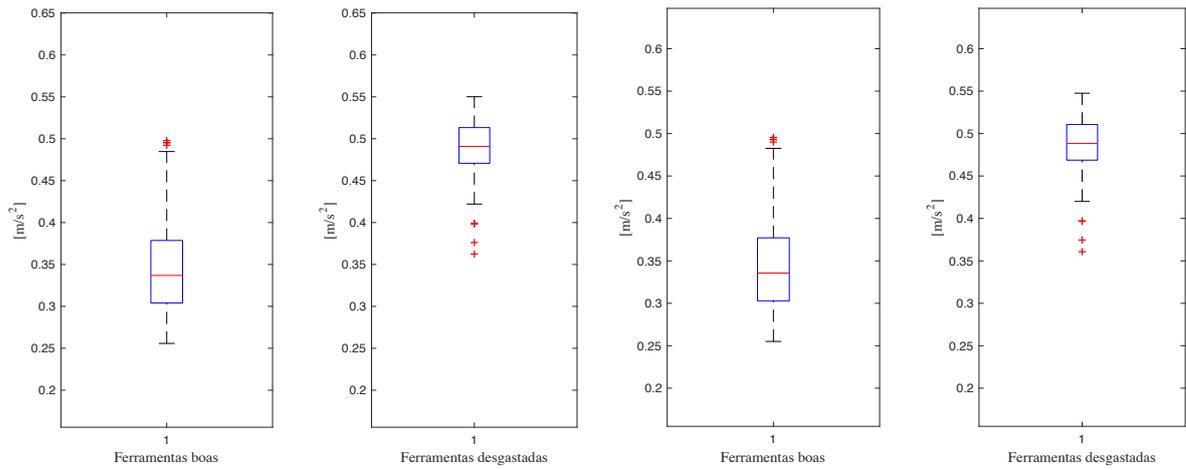
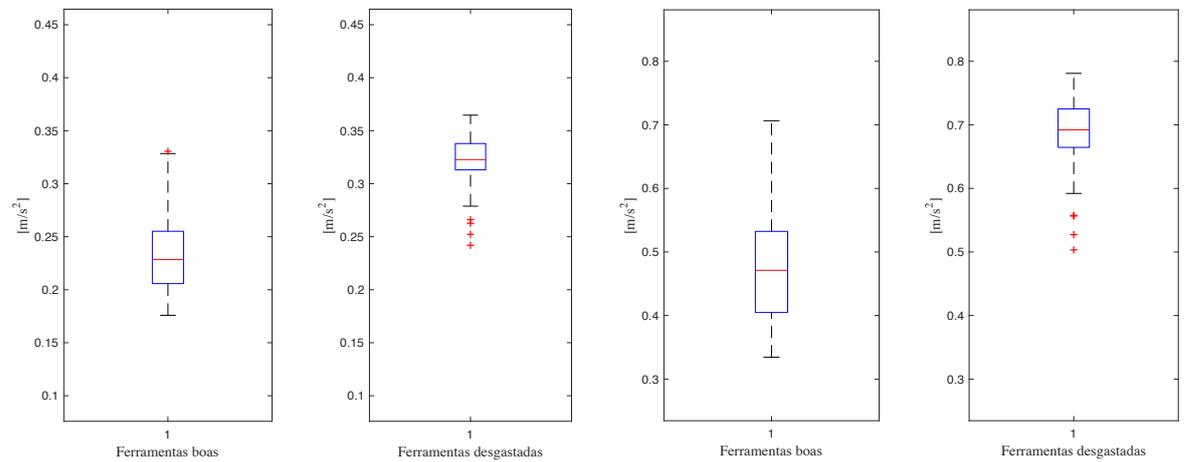


Figura 3.16 - Diagramas *Boxplot* | Posição Horizontal. Fonte: Autor (2018).



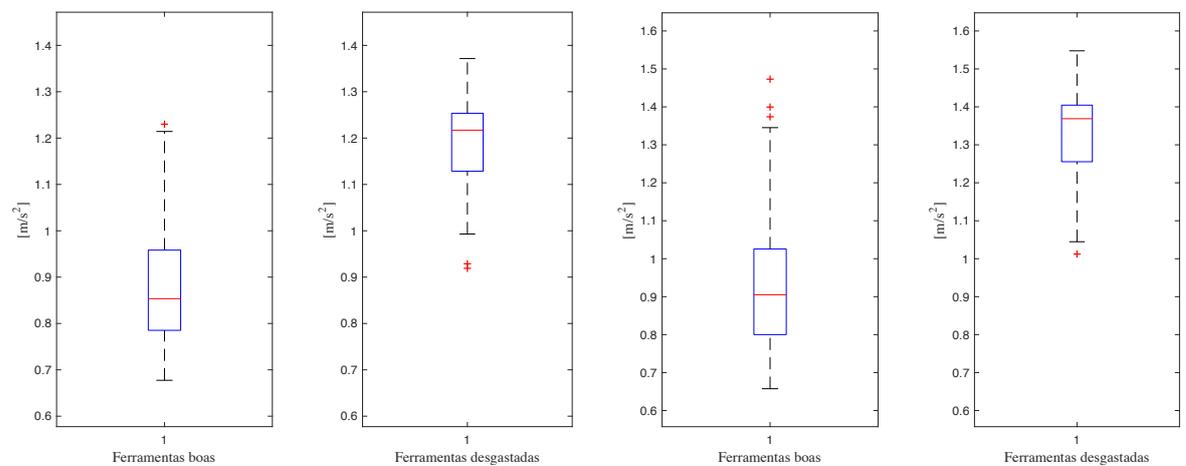
(e) Parâmetro 12

(f) Parâmetro 19



(g) Parâmetro 11

(h) Parâmetro 38



(i) Parâmetro 14

(j) Parâmetro 42

Figura 3.16 - Diagramas *Boxplot* | Posição Horizontal (Continuação). Fonte: Autor (2018).

Os Diagramas de Caixa (*Boxplot*) mostram que os parâmetros selecionados representam corretamente o problema em estudo. Além disso, verifica-se que as medianas das ferramentas em boas condições de uso não cruzam com a caixa das ferramentas desgastadas. Isso indica que existe uma diferença entre a mediana dos dois grupos do parâmetro selecionado. Os Diagramas de Caixa (*Boxplot*) mostram, mais uma vez, que existe uma boa correlação entre o problema em estudo e o parâmetro selecionado.

Na Fig. 3.17 são apresentados os Diagramas de Caixa (*Boxplot*) para os 10 melhores parâmetros referente a posição vertical para o Grupo II.

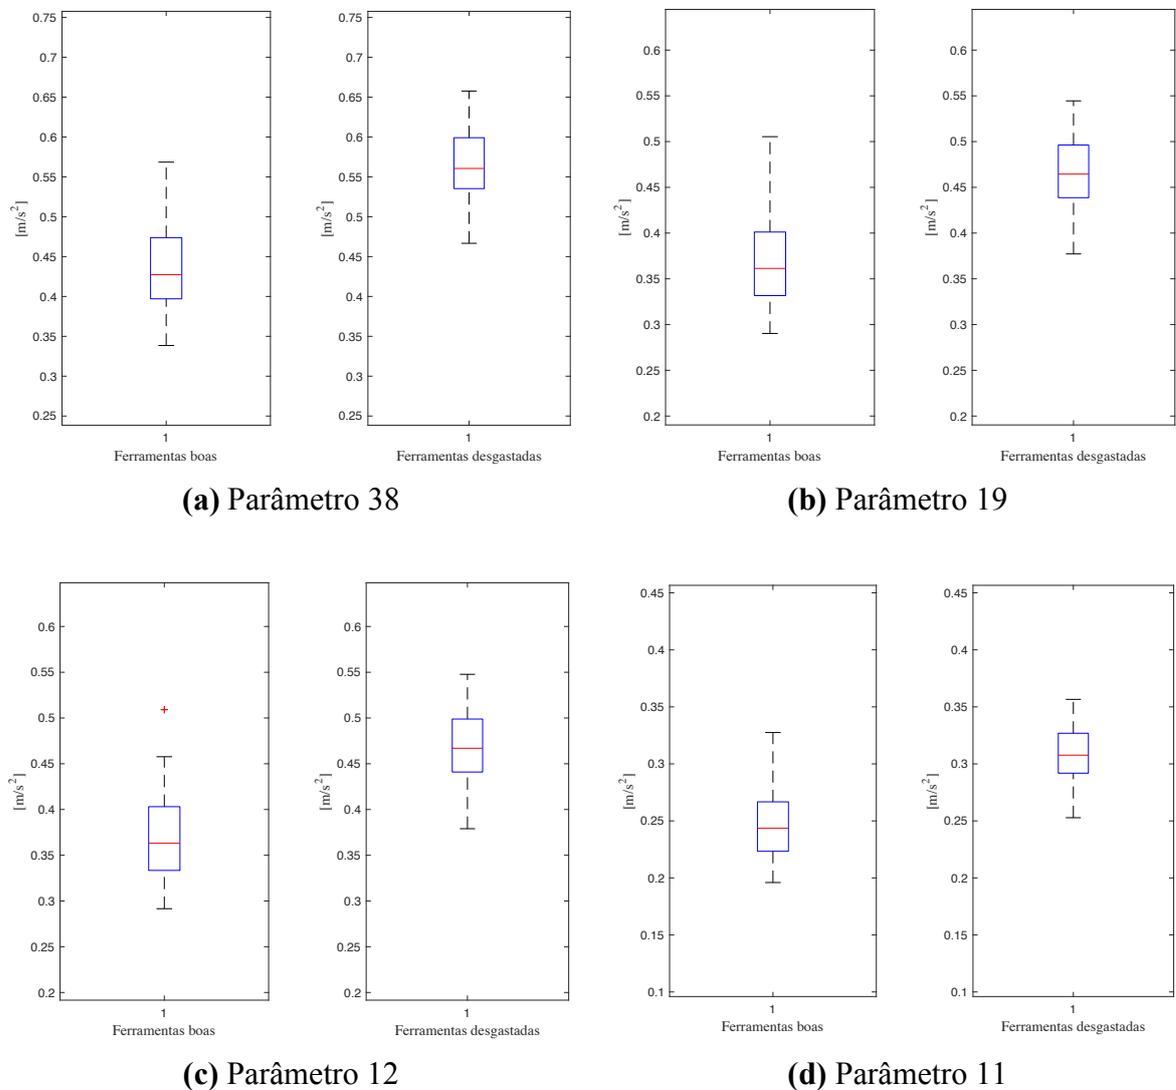
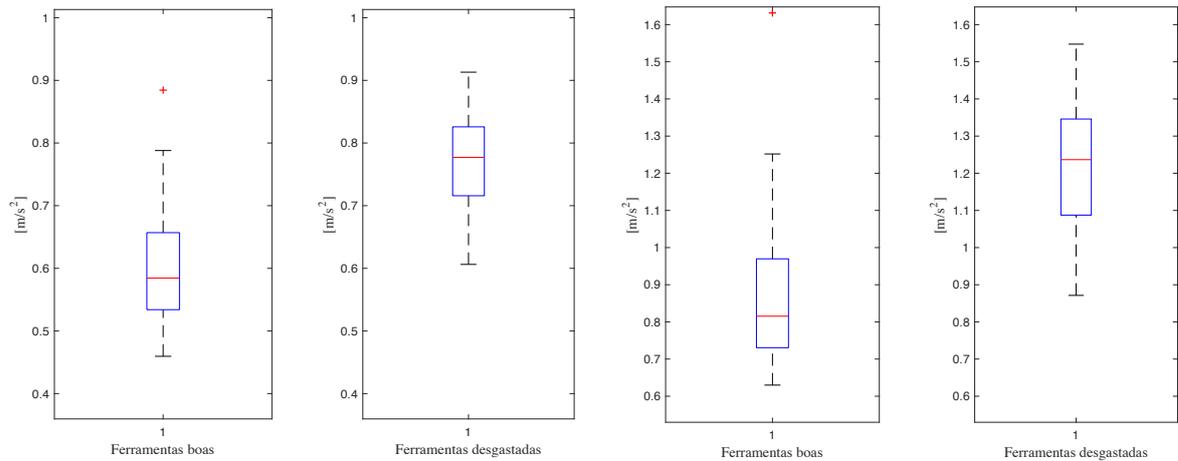
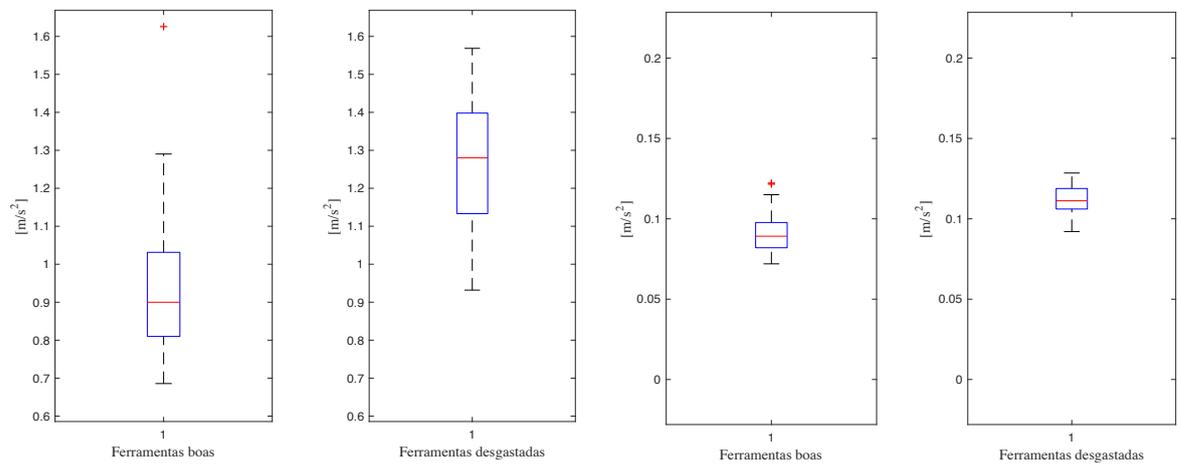


Figura 3.17 - Diagramas *Boxplot* | Posição Vertical. Fonte: Autor (2018).



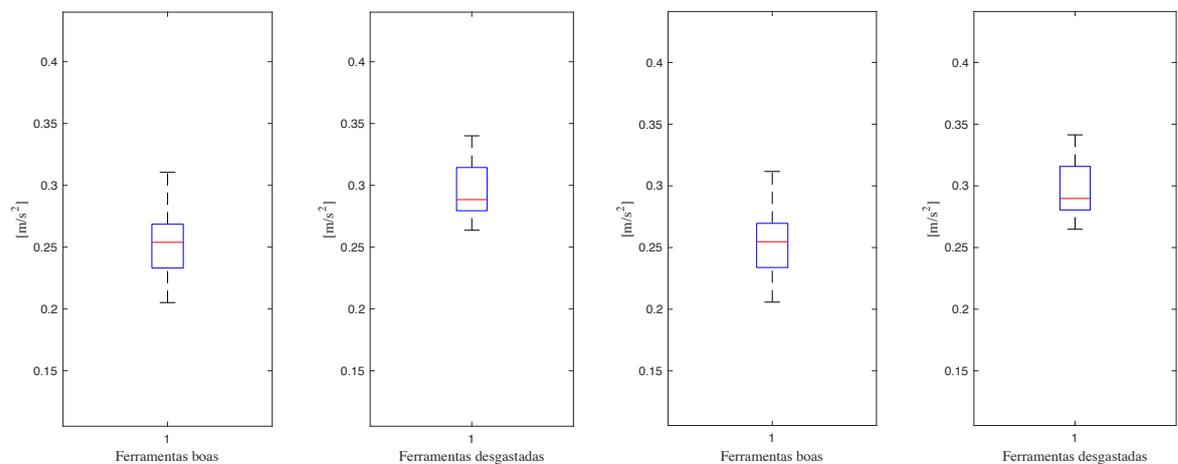
(e) Parâmetro 13

(f) Parâmetro 52



(g) Parâmetro 40

(h) Parâmetro 10



(i) Parâmetro 50

(j) Parâmetro 36

Figura 3.17 - Diagramas *Boxplot* | Posição Vertical (Continuação). Fonte: Autor (2018).

Conforme mostrado na Fig. 3.17 percebe-se que todos os parâmetros selecionados seguem a mesma análise realizada para a Fig. 3.16. Ou seja, todas as caixas e medianas dos parâmetros relacionados a ferramenta em boas condições de uso encontram-se abaixo daqueles para as ferramentas desgastadas e não se cruzam. Em contrapartida, na Fig. 3.16, apenas os parâmetros 12, 13 e 10 apresentam *outliers*, indicando assim, que os demais parâmetros não possuem valores extremos em suas amostras, o que aumenta a correlação do parâmetro com o caso em estudo.

Na Fig. 3.18 são apresentados os Diagramas de Caixa (*Boxplot*) para os 10 melhores parâmetros da combinação entre a posição vertical e horizontal para o Grupo II.

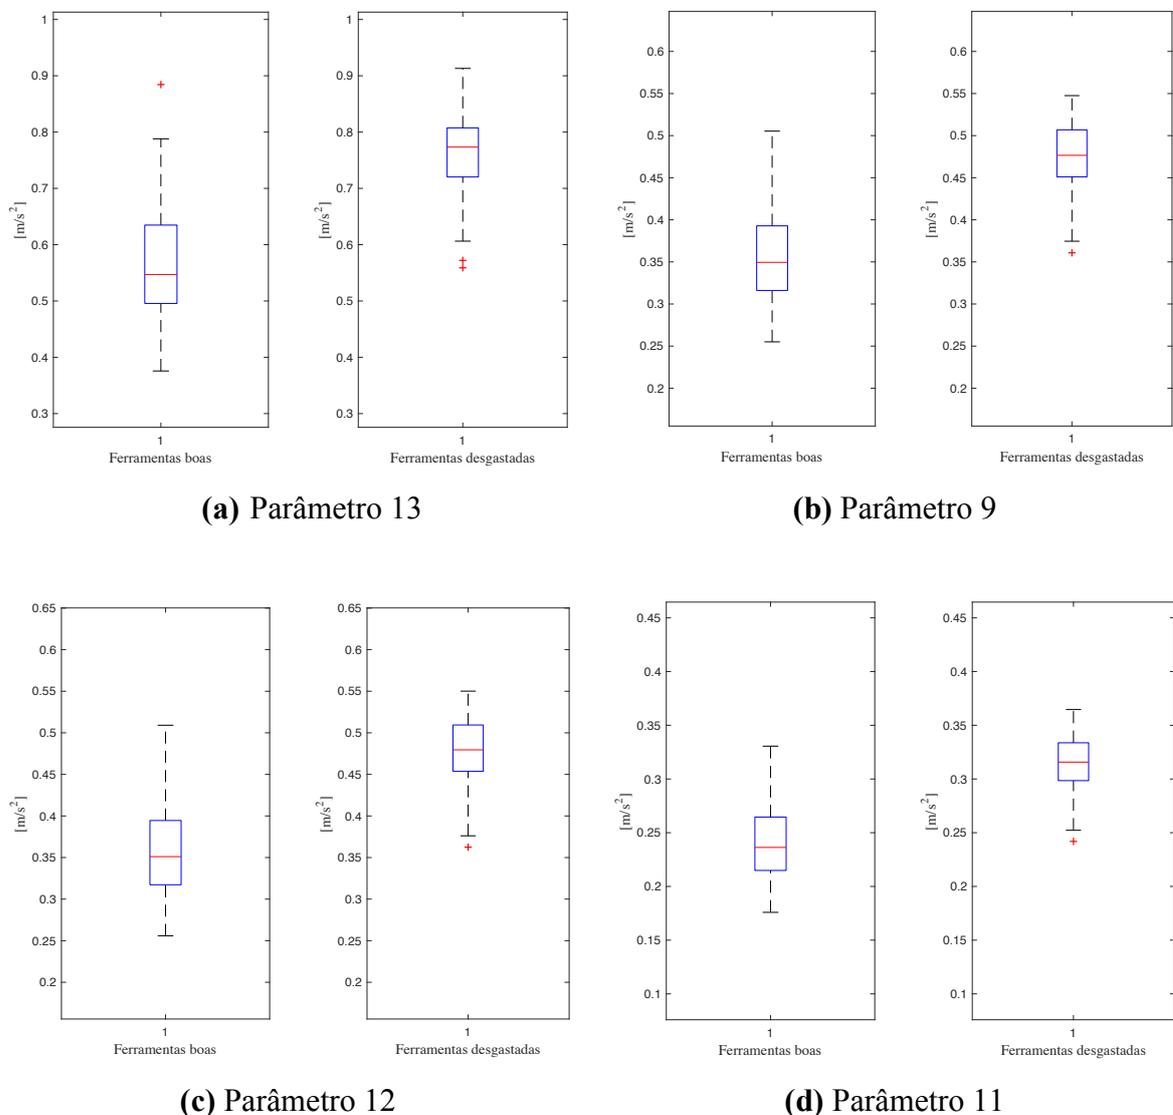


Figura 3.18 - Diagramas *Boxplot* | Posição Vertical e Horizontal. Fonte: Autor (2018).

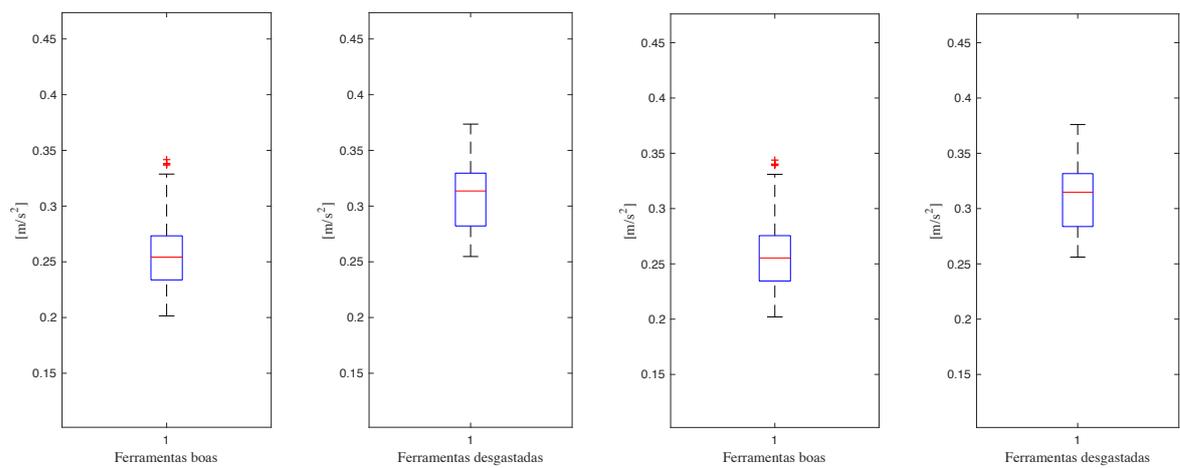
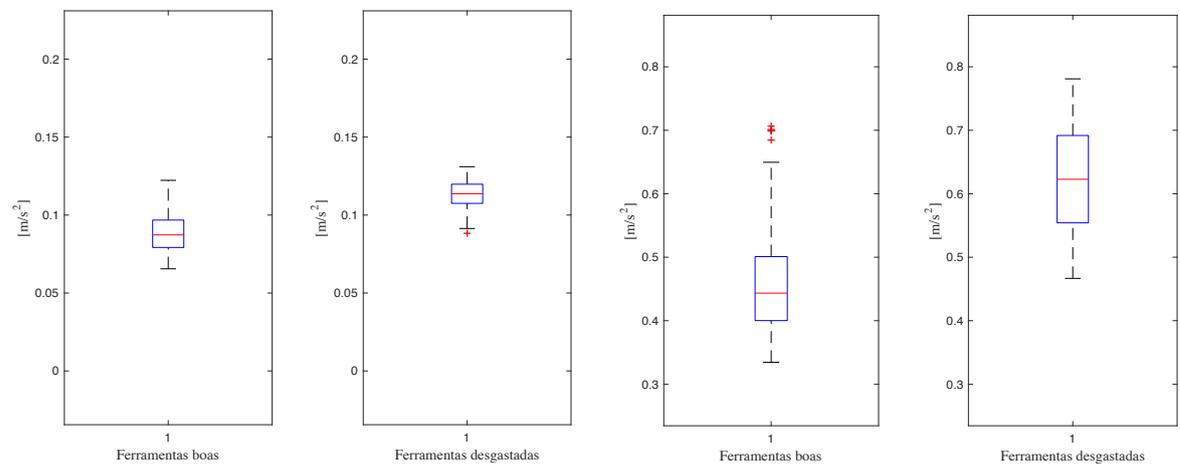
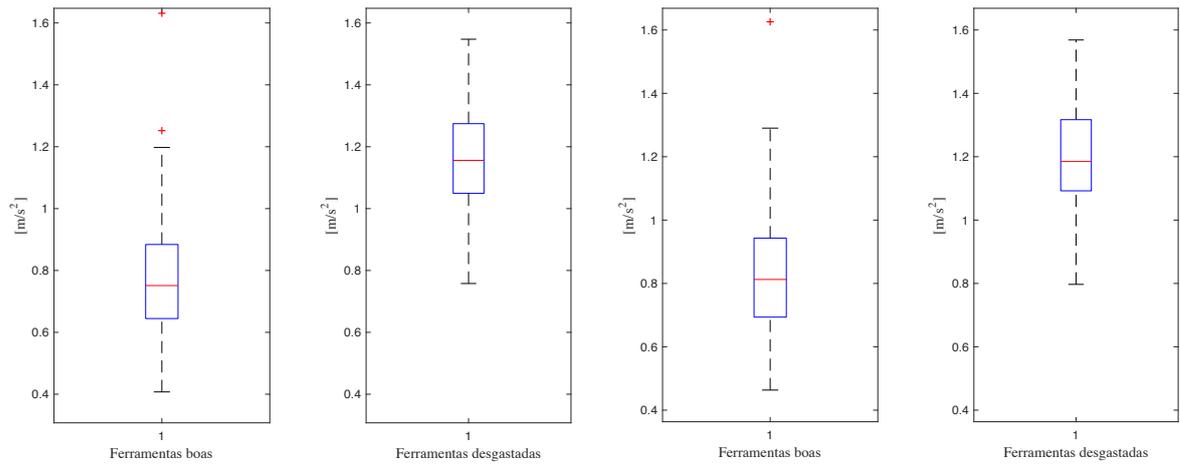


Figura 3.18 - Diagramas *Boxplot* | Posição Vertical e Horizontal (Continuação). Fonte: Autor (2018).

Conforme mostrado na Fig. 3.18, no que se refere a posição das caixas e medianas, nota-se que todos os parâmetros selecionados seguem a mesma análise realizada para as Fig. 3.16 e Fig. 3.17. Em geral, os parâmetros também apresentaram *outliers*, exceto os parâmetros 52 e 40.

3.3.3. Metodologia para a análise dos sinais através das Técnicas de Inteligência Artificial

Após selecionar os parâmetros que apresentam melhor correlação na identificação da condição de desgaste da ferramenta, os mesmos foram utilizados como parâmetros de entrada em três Técnicas de Inteligência Artificial previamente selecionadas.

Com base nos estudos desenvolvidos, verificou-se que os métodos W-kNN, SVM e SOM apresentam bons resultados para classificação de dados com as características dos estudados neste trabalho. Ou seja, dados onde os parâmetros possuem uma boa separação da mediana entre os grupos, visto na análise dos Diagramas de Caixa (*Boxplot*), que apresentam padrões característicos de sinais e onde exista presença de *outliers*.

Os dados do Grupo II foram divididos aleatoriamente em subgrupos para cada conjunto (vertical, horizontal e vertical | horizontal). Dessa forma tem-se dois subgrupo: um de treinamento contendo, aproximadamente, 90 % dos sinais e outro de teste com, aproximadamente 10 % dos sinais. Para cada conjunto (vertical, horizontal e vertical | horizontal) repetiu-se o procedimento supracitado 3 vezes, criando assim 3 subgrupos, variando apenas os dados para treinamento e teste. Esse procedimento permite validar a robustez e assertividade dos métodos e verificar a significância dos dados experimentais, Silva (2012). Além dos subgrupos criados, também foram treinados os métodos com todos os dados de cada conjunto sendo validados com os dados do Grupo I. Vale ressaltar que todo subgrupo foi validado com os dados do Grupo I.

Na Tab. 3.10 tem-se o resumo das divisões dos subgrupos de treinamento, teste e validação criados para o conjunto na posição horizontal.

Da mesma forma na Tab. 3.11 tem-se o resumo das divisões dos subgrupos de treinamento, teste e validação criados para o conjunto na posição vertical.

Na Tab. 3.12 tem-se o resumo das divisões dos subgrupos de treinamento, teste e validação para a posição vertical | horizontal.

Tabela 3.10 - Divisão dos subgrupos de treinamento, teste e validação - posição horizontal.

Subgrupo	Condição da ferramenta	Quantidade de dados		
		Conjunto - Horizontal		
		Treinamento	Teste	Validação
01	Em condição de uso	79	4	17
	Desgastada	26	6	11
	Todas as ferramentas	105	10	28
02	Em condição de uso	76	7	17
	Desgastada	29	3	11
	Todas as ferramentas	105	10	28
03	Em condição de uso	78	5	17
	Desgastada	27	5	11
	Todas as ferramentas	105	10	28
04	Em condição de uso	83	0	17
	Desgastada	32	0	11
	Todas as ferramentas	115	0	28

Fonte: Autor (2018).

Tabela 3.11 - Divisão dos subgrupos de treinamento, teste e validação - posição vertical.

Subgrupo	Condição da ferramenta	Quantidade de dados		
		Conjunto - Vertical		
		Treinamento	Teste	Validação
01	Em condição de uso	85	4	17
	Desgastada	25	8	11
	Todas as ferramentas	110	12	28
02	Em condição de uso	82	7	17
	Desgastada	28	5	11
	Todas as ferramentas	110	12	28
03	Em condição de uso	83	6	17
	Desgastada	27	6	11
	Todas as ferramentas	110	12	28
04	Em condição de uso	89	0	17
	Desgastada	33	0	11
	Todas as ferramentas	122	0	28

Fonte: Autor (2018).

Tabela 3.12 - Divisão dos subgrupos de treinamento, teste e validação posição vertical | horizontal.

Subgrupo	Condição da ferramenta	Quantidade de dados		
		Conjunto - Vertical Horizontal		
		Treinamento	Teste	Validação
01	Em condição de uso	164	8	34
	Desgastada	49	16	22
02	Todas as ferramentas	213	24	56
	Em condição de uso	155	17	34
	Desgastada	58	7	22
	Todas as ferramentas	213	24	56
03	Em condição de uso	160	12	34
	Desgastada	53	12	22
04	Todas as ferramentas	213	24	56
	Em condição de uso	172	0	34
	Desgastada	65	0	22
	Todas as ferramentas	237	0	56

Fonte: Autor (2018).

A fim de verificar qual técnica apresenta melhor resultado perante a classificação do desgaste da ferramenta, os três métodos propostos foram testados utilizando a mesma quantidade de parâmetros de entrada, no caso cinco parâmetros. Para esse teste utilizou-se somente o conjunto composto pelos sinais da vertical e horizontal. Dessa forma, tem-se quantidade suficiente de dados para fornecer representatividade aos testes.

Para a rede competitiva Mapas Auto-organizáveis (SOM, do inglês: *Self-Organizing Map*) utilizou-se duas classes de classificação dos parâmetros de entrada, tendo em vista que o objetivo do trabalho é determinar a condição da ferramenta sendo: em boas condições de uso ou desgastada. Além disso, trabalhou com uma baixa taxa de aprendizado para definição dos pesos, 0,01, que, de acordo com Haykin (1998), para garantir o sucesso do aprendizado deve-se usar uma taxa de aprendizado baixa.

Para os métodos k Vizinhos mais Próximos (W-kNN, do inglês: *K-Nearest Neighbor*) e Máquina de Vetores de Suporte (SVM, do inglês: *Support Vector Machines*), utilizou-se cinco validações cruzadas no treinamento a fim de proteger os resultados contra o erro de *overfitting*. Dessa forma, o conjunto de teste é dividido em subconjuntos, os quais são testados usando o

classificador treinado e verificando o erro. Assim, os dados de cada conjunto são previstos com maior assertividade.

A SVM utilizou função Kernel Gaussiana, com escala automática, a qual durante a validação cruzada é julgada e definida como sendo a que obteve maior taxa de acerto. Para a decomposição multiclasse utilizou-se o um-contra-um.

Já para a técnica de W-kNN utilizou-se dez vizinhos, com métrica de distância euclidiana e métrica de cálculo dos pesos através do inverso do quadrado.

Todos os testes foram realizados através do *software* Matlab®. Os resultados são apresentados no Cap. IV.

Para a técnica que obteve melhor taxa de assertividade nos testes supracitados foram testadas diferentes configurações variando a quantidade de parâmetros de entrada e parâmetros do método. Testou-se também a taxa de assertividade ao utilizar somente o conjunto vertical, ou somente o conjunto horizontal, ou utilizando o conjunto com os sinais das posições horizontais e verticais juntos. Os resultados são apresentados no Cap. IV.

CAPÍTULO IV

RESULTADOS E DISCUSSÃO

Os dados obtidos foram analisados a fim de verificar a possibilidade de um sinal de vibração identificar a condição de desgaste da ferramenta. Considerou-se como uma ferramenta em boas condições de uso aquela que apresentava $VB_{Bmax} \leq 0,35$ mm e desgastada $VB_{Bmax} > 0,35$ mm. Inicialmente analisou-se os sinais do domínio da frequência a fim de tentar correlacionar o desgaste à determinadas bandas de frequência e suas respectivas amplitudes. Posteriormente testou-se as três Técnicas de Inteligência Artificial selecionadas e apresentou-se os resultados obtidos. Para a técnica que apresentou melhor taxa de acerto, avaliou-se a posição do sensor na máquina que apresentou melhor resultado para a técnica. Além disso, estudou-se diferentes configurações para a técnica escolhida e avaliou-se os erros obtidos. Por fim, analisou-se o desgaste final de cada ferramenta utilizada.

4.2. Determinação da melhor técnica de classificação

Seguindo a metodologia no Capítulo III, inicialmente buscou-se determinar quais Técnicas de Inteligência Artificial, dentre as testadas (W-kNN, SVM e SOM), apresentava melhor resultado na classificação do desgaste das ferramentas. Os resultados utilizando cinco parâmetros de entrada, para o conjunto selecionado (Vertical | Horizontal), são apresentados na Tab 4.1.

Tabela 4.1 - Resultado do teste para as Técnicas de Inteligência Artificial.

Subgrupo	Taxa de Acerto (%)								
	Treinamento			Validação I			Validação II		
	SOM	KNN	SVM	SOM	KNN	SVM	SOM	KNN	SVM
01	78,4	90,1	89,7	87,5	79,2	83,3	83,9	87,5	85,7
02	80,7	89,2	89,7	83,3	95,8	91,7	83,9	89,3	91,1
03	79,8	90,6	90,1	83,3	87,5	87,5	83,9	92,8	91,1
04 - Validação	81,0	90,3	89,5	-	-	-	83,9	92,8	92,8
Assertividade									
Final	79,9	90,1	89,8	84,7	87,5	87,5	83,9	90,6	90,1

Fonte: Autor (2018).

Avaliando a Tab. 4.1 nota-se que a rede neural competitiva SOM apresentou desempenho levemente inferior as demais técnicas testadas. Apesar da rede neural SOM também ser utilizada para classificar dados desbalanceados, a mesma apresenta melhores resultados quando se trabalha com dados balanceados, o que não é o caso dos conjuntos em estudo. Dessa forma, atribui-se a este fato um dos principais motivos para o resultado obtido pela técnica.

Analisando as técnicas KNN e SVM nota-se que ambas tiveram desempenho igual na fase de teste. Por outro lado, a técnica KNN apresentou resultado ligeiramente superior para a fase de treinamento e validação, motivo que levou a optar pela técnica nas análises subsequentes.

Conforme metodologia explicada no Capítulo III ressalta-se que não existem resultados para a fase de teste referente ao subgrupo 04, ou seja, validação. Isso se deve ao fato de todos os dados (Grupo II), exceto os de validação (Grupo I), foram utilizados para treinar as técnicas. Nos demais subgrupos (01, 02 e 03), os dados referentes ao Grupo II foram particionados em 90 % para treinamento e 10 % para teste.

4.3. Determinação da quantidade de parâmetros de entrada e posição do sensor

Após determinação da Técnica de Inteligência Artificial a ser utilizada, de acordo com o item 4.2 avaliou-se o desempenho da mesma em função da posição do sensor, ou seja, utilizando somente a posição vertical, ou horizontal ou as duas. Além disso, analisou-se a

influência da quantidade de parâmetros de entrada usando 10 diferentes configurações. Os resultados são apresentados na Tab. A5.1, Tab. A5.2 e Tab. A5.3, Apêndice V, devido a grande quantidade de dados, uma análise resumida é apresentada na Tab. A5.4, também disponível no Apêndice V.

A fim de tornar a análise das Tab. A5.1, Tab. A5.2 e Tab. A5.3 mais simples, devido ao grande número de resultados obtidos, calculou-se a taxa de acerto final para cada posição em relação a quantidade de parâmetros, apresentada na Tab. A5.4, Apêndice V, e Fig. 4.1. Em outras palavras, a taxa de acerto final corresponde ao somatório da quantidade de acerto nas validações I e II para todos os subgrupos referente à posição em análise, dividido pelo número total de amostras testadas para cada posição.

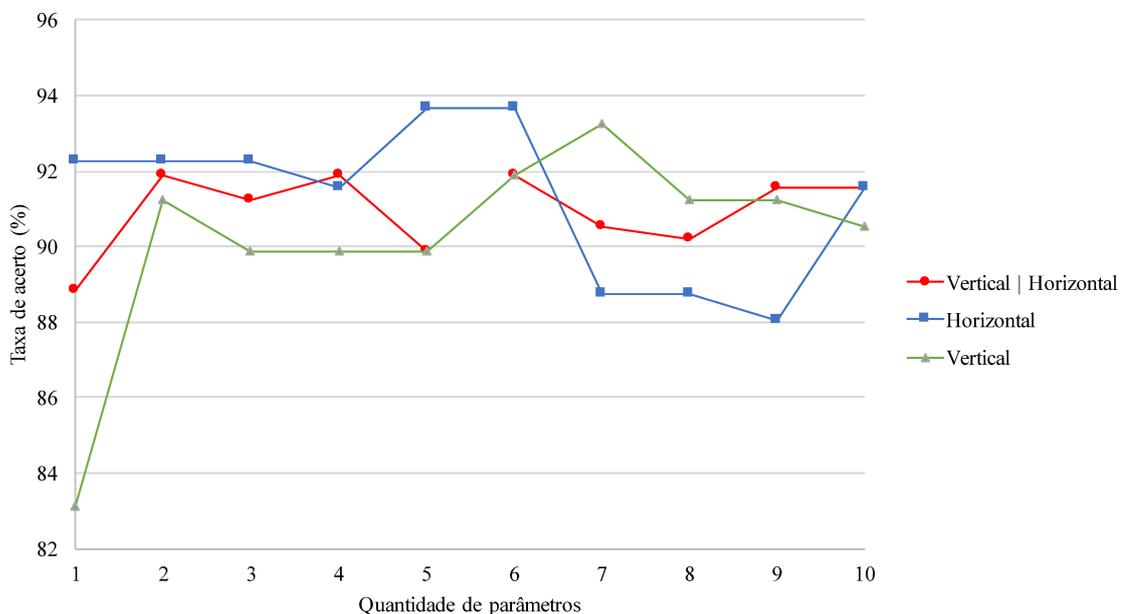


Figura 4.1 - Taxa de acerto final para as posições testadas. Fonte: Autor (2018).

Analisando os resultados apresentados na Tab. A5.4, Apêndice V, e resumidos na Fig. 4.1, nota-se que o conjunto que obteve a melhor taxa de acerto ao final das validações I e II de todos os subgrupos, foi a posição horizontal. Em relação a quantidade de parâmetros de entrada tem-se os mesmos valores, para cinco e seis parâmetros (93,7 % de acerto). Tendo em vista que utilizar uma menor quantidade de parâmetros reduz o custo computacional da técnica, devido a menor quantidade de cálculos necessários, optou-se por trabalhar com 5 parâmetros para o caso em estudo. Na Tab. 4.2 tem-se os cinco parâmetros selecionados.

Tabela 4.2 - Parâmetros selecionados.

Parâmetro	Descrição dos Parâmetros
52	Nível de energia do envelope filtrado com filtro passa banda entre 500 a 3 000 Hz
40	Nível de energia do envelope filtrado com filtro passa baixa em 3 000 Hz
13	Nível de energia do sinal filtrado com filtro passa baixa em 1 000 Hz
20	Nível de energia do sinal filtrado com filtro passa banda entre 500 a 3 000 Hz
12	Nível de energia do sinal filtrado com filtro passa baixa em 500 Hz

Fonte: Autor (2018).

Analisando os dados apresentados na Tab. 4.2 verifica-se que os parâmetros que apresentam melhor correlação com o problema em estudo são relacionados ao domínio da frequência, com banda de frequência máxima de 3 000 Hz, sendo eles, nível de energia do envelope e nível de energia do sinal. Esses resultados estão de acordo com o estudo realizado por Dimla (2002), onde mostrou-se que o domínio do tempo é mais sensível a variação nas condições de corte do que em relação ao desgaste. Em contrapartida, o domínio da frequência apresenta boa correlação do sinal de vibração com o desgaste da ferramenta.

Além disso, comparando com os sinais no domínio da frequência apresentados na Fig. 3.15, nota-se que as bandas de frequência dos parâmetros selecionados foram as mesmas que apresentaram maior diferença entre o sinal para a ferramenta em boas condições de uso e desgastada.

4.4. Determinação da melhor configuração para o método de inteligência artificial

Após determinação do melhor posicionamento para sensor de vibração (horizontal), além da quantidade de parâmetros de entradas (cinco) a ser utilizada nas Técnicas de Inteligência Artificial, estudou-se a influência do valor de k , número de vizinhos, da técnica W-kNN aplicada no trabalho.

Conforme comprovado por Dudani (1975), Gou *et al.* (2012) e Yigit (2013), em geral, para quantidade de vizinhos (k) maior do que dez a taxa de acerto do método W-kNN se mantém constante ou é reduzida, conforme pode ser visto na Fig. 4.2, proposta por Dudani (1975).

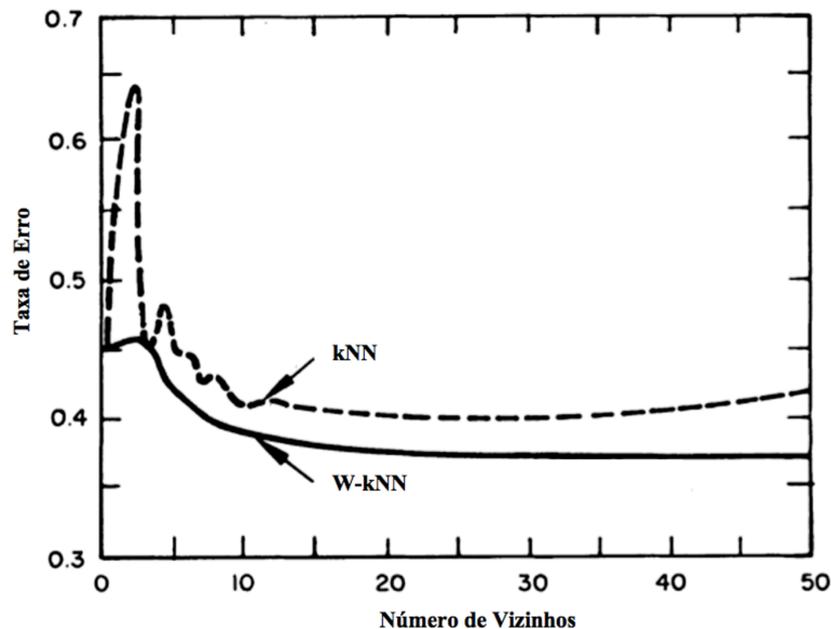


Figura 4.2 - Comparação da probabilidade de erro em relação a quantidade de vizinhos para o método kNN e W-kNN. Fonte: Adaptado Dudani (1975).

Afim de validar as considerações supracitadas variou-se o valor de k entre um a vinte, os quais foram testadas para a posição horizontal com cinco parâmetros, tendo em vista ser a melhor configuração analisada. Para os valores da métrica de distância entre as amostras e métrica para os pesos, utilizou-se a Distância Euclidiana e Inverso da Distância Quadrada, respectivamente.

Cada amostra dos grupos de Validação 01 e 02 foram testadas separadamente utilizando o modelo treinado. Para simular uma situação de aplicação industrial, após treinamento do modelo, os dados foram testados individualmente em relação ao modelo. Os resultados obtidos são mostrados na Tab. 4.3.

Conforme realizado anteriormente, a fim de tornar a análise da Tab. A6.1 mais simples devido ao grande número de resultados obtidos, calculou-se a taxa de acerto final para cada valor de k , apresentada na Tab. A6.2, Apêndice VI, e resumida na Fig. 4.3. Em outras palavras, a mesma corresponde ao somatório da quantidade de acerto nas validações I e II para todos os subgrupos, dividido pelo número total de amostras testadas para cada posição.

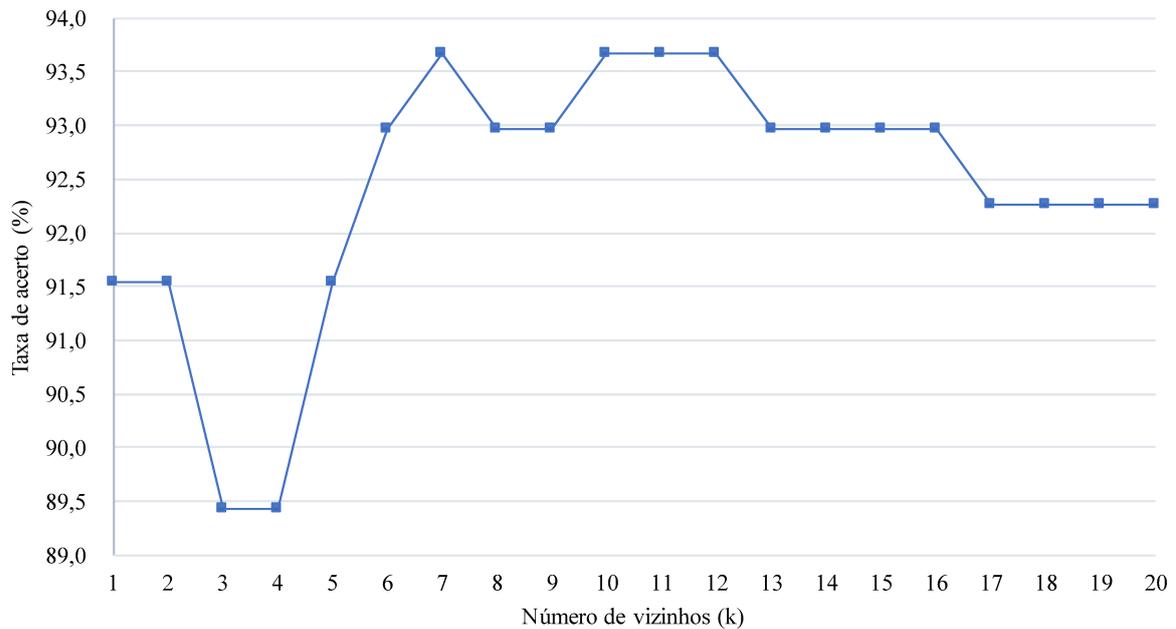


Figura 4.3 - Taxa de acerto do método W-kNN em função da quantidade de número de vizinhos (**k**). Fonte: Autor (2018).

Analisando os resultados obtidos na Tab. A6.2, Apêndice VI e apresentados na Fig. 4.3, nota-se que os valores de **k** (quantidade de vizinhos) que obtiverem a melhor taxa de acerto ao final das validações I e II de todos os subgrupos, foram **k** = 7, 10, 11 e 12 (93,7 % de acerto). Utilizando o mesmo critério adotado anteriormente para a seleção da quantidade de parâmetros, ou seja, reduzir o custo computacional da técnica, optou-se por trabalhar com o valor de **k** = 7.

Dessa forma, uma quantidade menor de amostras vizinhas será levada em consideração durante o teste, aumentando a velocidade dos cálculos e reduzindo o custo computacional, sem comprometer o desempenho, conforme mostrado pelos resultados.

4.5. Análise da taxa de acerto final

Após todas as análises realizadas, obteve-se uma taxa de acerto final de 93,7 % para o sensor na posição horizontal e utilizando o método W-kNN com as configurações, apresentadas a seguir.

- Métrica de distância entre as amostras: Distância Euclidiana.
- Métrica de distância para os pesos: Inverso da Distância Quadrada.
- Quantidade de Vizinhos (**k**): 7.
- Quantidade de Parâmetros: 5.

A fim de entender os motivos que levaram o método a ter 6,3 % de erro na validação, estudou-se separadamente todos os testes que foram classificados de forma errada.

Na Tab. 4.3 tem-se as informações sobre os testes que apresentaram erro na classificação. Analisou-se os erros para cada subgrupo, em relação a Validação I e II. O número do teste apresentado, refere-se à identificação proposta na Tab. A2.1, Apêndice II, para o Grupo 01 e Tab. A2.2, Apêndice II, para o Grupo 02.

Tabela 4.3 - Análise dos erros de classificação em relação ao desgaste.

Subgrupo	Validação	Grupo pertencente	Teste	Desgaste V_{Bmax} (mm)	
				Inicial	Final
01	I	02	119	0,394	0,399
	II	01	13	0,228	0,228
	II	01	18	0,259	0,259
02	II	01	13	0,228	0,228
	II	01	18	0,259	0,259
03	I	02	100	0,352	0,357
	II	01	13	0,228	0,228
04	II	01	24	0,425	0,433
	II	01	13	0,228	0,228

Fonte: Autor (2018).

Com relação ao Grupo 01 (Validação II), os testes que apresentaram erro de classificação foram o 13, 18 e 24. No Grupo 02 (Validação I) foram os testes 100 e 119.

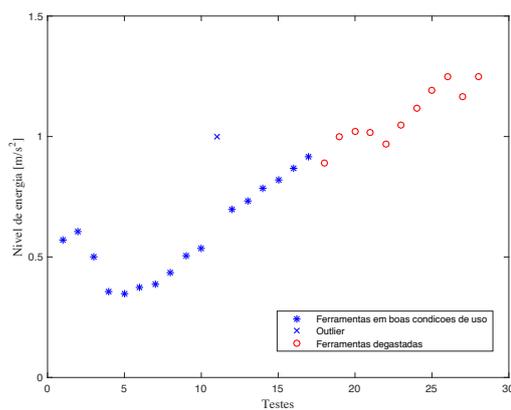
Em relação a Validação I, os erros consistem na classificação da ferramenta como em boas condições de uso. Analisando o desgaste, nota-se que ambas se encontram acima do valor determinado como desgaste máximo ($V_{Bmax} = 0,35$ mm), ou seja, deveriam ser classificadas como desgastadas.

Já em relação a Validação II, os testes 13 e 18 consistem na classificação da ferramenta como em desgastada, sendo que analisando o desgaste nota-se que ambas se encontram abaixo do valor determinado como desgaste máximo ($V_{Bmax} = 0,35$ mm), ou seja, deveriam ser classificadas como em boas condições de uso. O teste 24, por outro lado, apresentou valor de desgaste acima do valor máximo, sendo classificado como em boas condições de uso, quando deveria ser classificado como ferramenta desgastada.

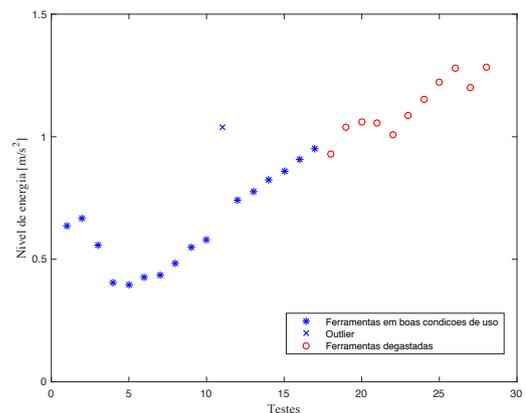
A fim de verificar o motivo dos testes supracitados terem sido classificados de forma errônea durante a fase de validação, aplicou-se o Critério de Chauvenet. Buscou-se avaliar se os mesmos são considerados *outliers* (valores extremos). Se sim, não se enquadram na tendência dominante do grupo e podem ser descartados. O critério foi aplicado aos 5 parâmetros selecionados avaliando cada teste.

De todos os testes avaliados somente o teste 13 apresentou valores dos parâmetros maiores do que a razão Rc ($n=17$, $Rc = 2,18$) proposta pelo método. Dessa forma, pode-se concluir que o teste 13 é um *outlier* podendo ser excluído do conjunto de validação.

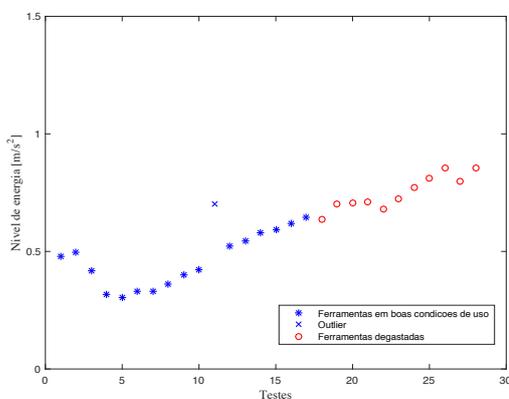
Na Fig. 4.4, são apresentadas a distribuição dos valores para os cinco parâmetros utilizados, onde é possível perceber, visualmente, a discrepância do teste 13 em relação aos demais valores do grupo para a ferramenta em boas condições de uso. Na Fig. 4.4 o teste 13 está identificado como 11 devido a exclusão de dois sinais conforme explicado no Capítulo III e representado com o símbolo **x**.



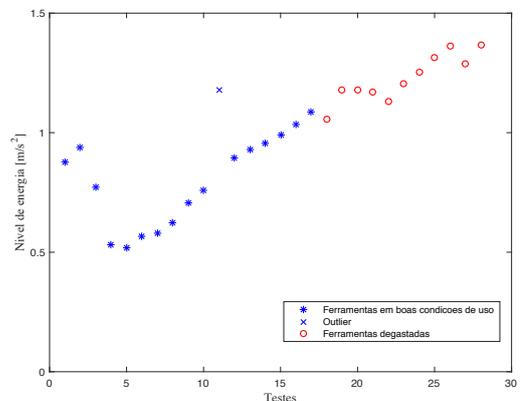
(a) Parâmetro 52



(b) Parâmetro 40

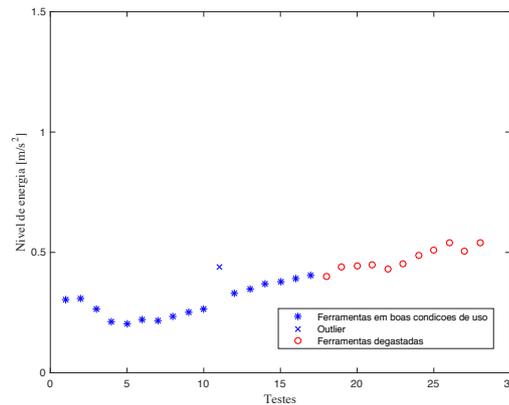


(c) Parâmetro 13



(d) Parâmetro 20

Figura 4.4 - Representação dos valores para os cinco parâmetros utilizados. Fonte: Autor (2018).



(e) Parâmetro 12

Figura 4.4 - Representação dos valores para os cinco parâmetros utilizados (Continuação). Fonte: Autor (2018).

Pode-se justificar os valores obtidos para o teste 13 e, conseqüentemente, sua discrepância em relação ao grupo das ferramentas consideradas em boas condições de uso, por um dos motivos apresentados a seguir.

- Como não é possível controlar a homogeneidade da microestrutura, tanto da ferramenta como do material, pode ter havido uma diferença nas mesmas, gerando maior vibração.
- Devido a aleatoriedade do teste, após cada passe a ferramenta era removida do suporte, e a próxima ferramenta fixada. A fixação ocorria através do aperto sistemático do parafuso do suporte, usando sempre a mesma quantidade de voltas e posição inicial. Mesmo utilizando essa padronização, o parafuso pode ter perdido a capacidade de aperto inicial devido a sequência de montagem e desmontagem, aumentando a liberdade da ferramenta e, conseqüentemente, gerando maior vibração.

Além de verificar se o teste em análise é um *outlier* também estudou-se o valor do seu desgaste em relação ao grupo em que foi classificado. Analisando a Tab. 4.3, nota-se que dos erros cometidos pelo método, apenas o teste 100 apresentou valor próximo ao determinado como desgaste máximo ($VB_{Bmax} = 0,35$ mm).

Percebe-se que para o teste 100 o desgaste inicial, e após o passe, encontram-se bem próximos ao valor de desgaste máximo, apresentando diferença somente na terceira casa decimal. Este erro do método justifica-se devido a grande dificuldade do mesmo diferenciar valores com esse nível de precisão. Vale ressaltar que para o passe seguinte da ferramenta, onde o valor de desgaste medido foi de 0,363 mm, o método acertou a classificação, mostrando a

precisão da técnica. Dessa forma, pode-se concluir que o teste 100 não é considerado um erro de classificação do método.

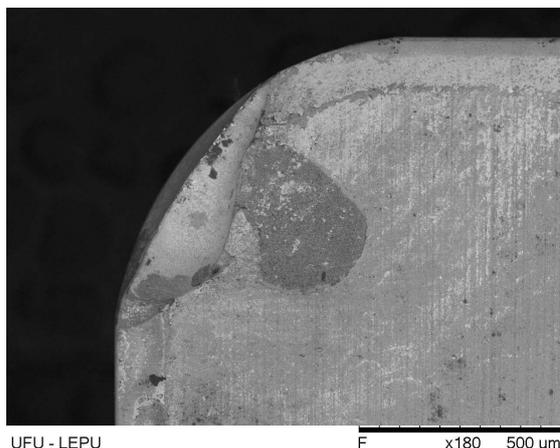
Para os testes 18, 24 e 119, após análise das técnicas supracitadas, e verificação do sinal no domínio do tempo e da frequência, conclui-se que os mesmos podem ser considerados erros de classificação do método, já que não apresentam justificativas técnicas coerentes para o erro.

Portanto, avaliando novamente a taxa de acerto do método de classificação W-KNN para o conjunto de dados em estudo, excluindo o teste 13, considerado um *outlier* e não considerando o teste 100 como erro, tem-se um acerto de 97,1 %.

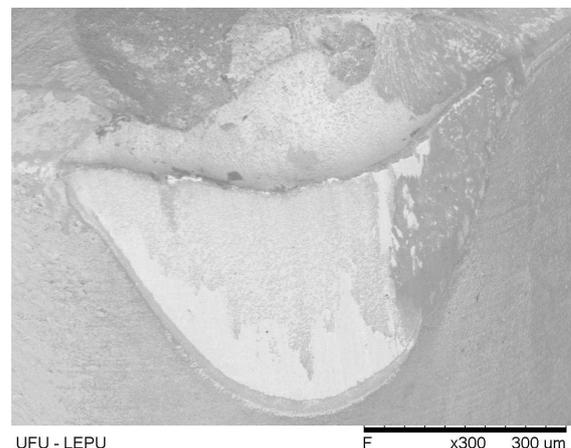
4.6. Análise da forma do desgaste final

Além das análises realizadas utilizando as Técnicas de Inteligência Artificial para classificação da condição de desgaste da ferramenta, verificou-se o tipo de desgaste presente nas ferramentas ao final dos testes.

Conforme metodologia apresentada no Capítulo III, tem-se as representações das arestas de corte, de acordo com as fotos obtidas através do microscópio eletrônico de varredura TM3000, Fig. 4.5.

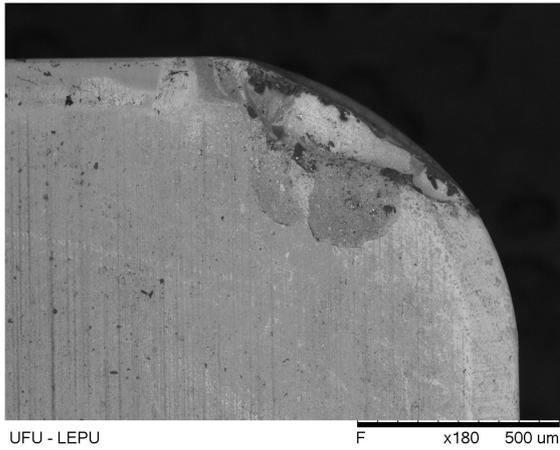


(a1) Superfície de saída da aresta F02A1

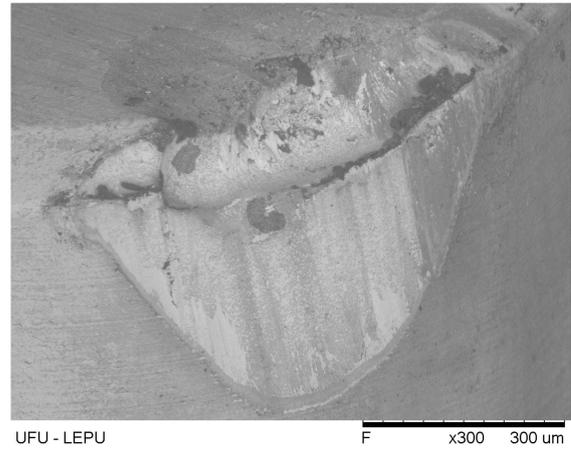


(a2) Superfície de folga da aresta F02A1

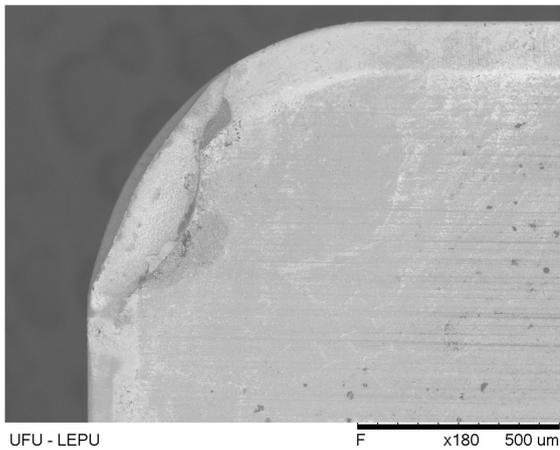
Figura 4.5 - Representação das arestas de corte após o final dos testes. Fonte: Autor (2018).



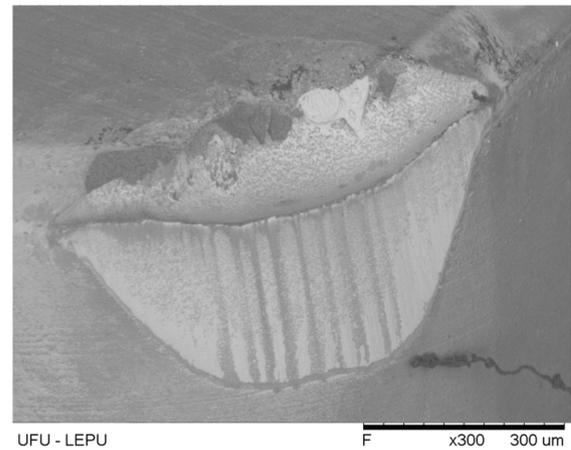
(b1) Superfície de saída da aresta F02A2



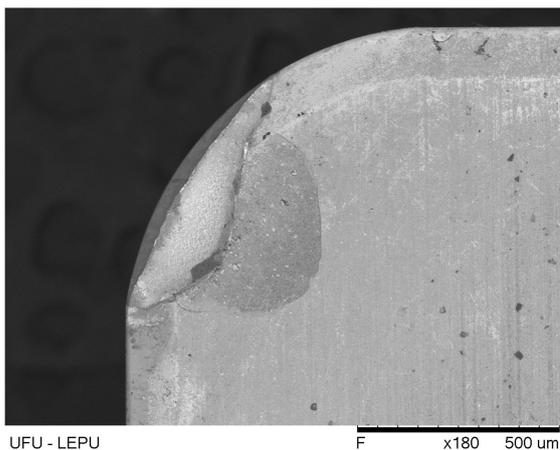
(b2) Superfície de folga da aresta F02A2



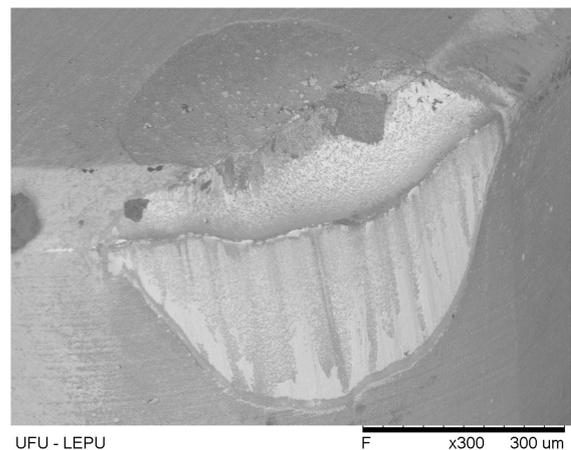
(c1) Superfície de saída da aresta F03A1



(c2) Superfície de folga da aresta F03A1



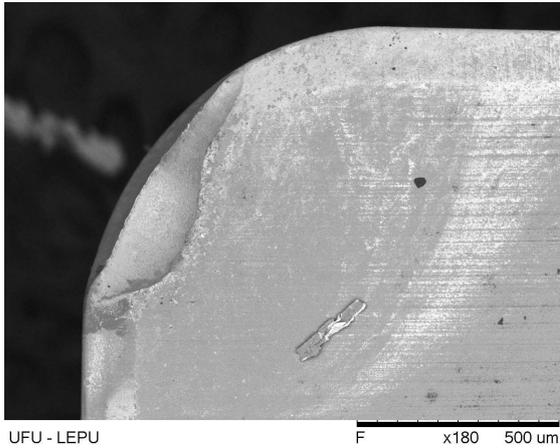
(d1) Superfície de saída da aresta F04A1



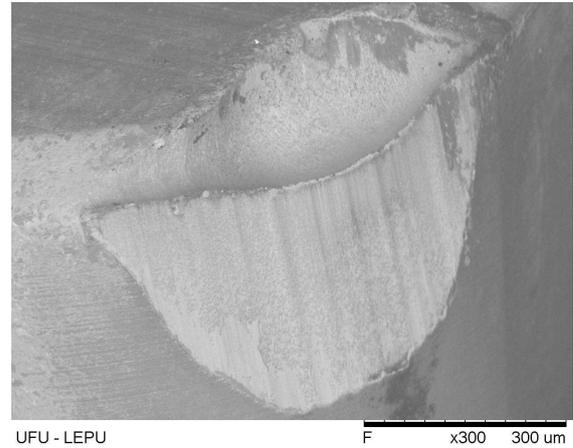
(d2) Superfície de folga da aresta F04A1

Figura 4.5 - Representação das arestas de corte após o final dos testes (Continuação).

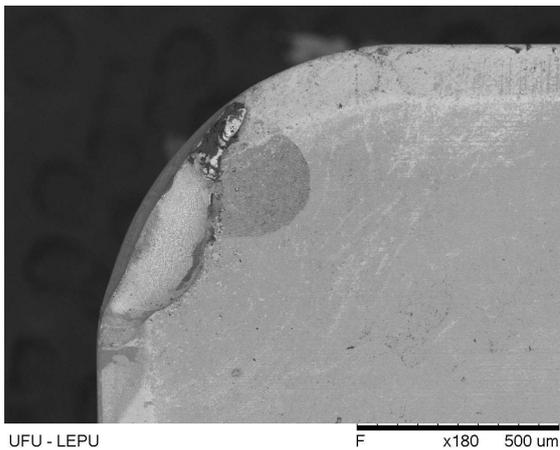
Fonte: Autor (2018).



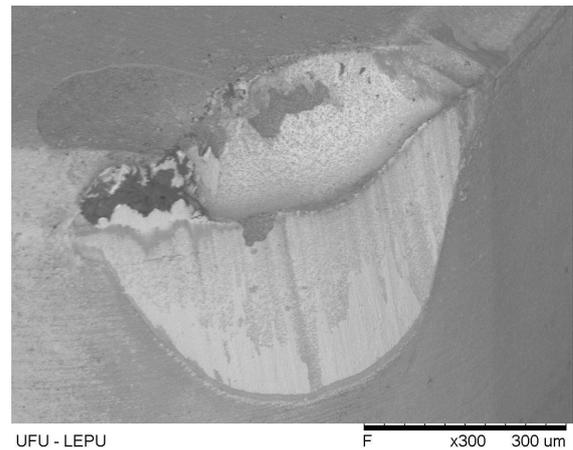
(e1) Superfície de saída da aresta F05A1



(e2) Superfície de folga da aresta F05A1



(f1) Superfície de saída da aresta F06A1



(f2) Superfície de folga da aresta F06A1

Figura 4.5 - Representação das arestas de corte após o final dos testes (Continuação).

Fonte: Autor (2018).

Analisando a Fig. 4.5 nota-se, pela vista frontal, a presença do desgaste de flanco, causado principalmente pela abrasão dos constituintes duros no material da peça. Como consequência pode-se ter a deterioração do acabamento da peça devido a modificação da geometria da aresta original, resultando também em mudanças de dimensões da mesma. Além disso, o aumento do desgaste de flanco gera instabilidade no processo, aumentando os níveis de vibração conforme mostrado no item 4.1.

Pela vista da superfície de folga, também é possível identificar o desgaste de cratera, possivelmente gerado mecanismo de difusão. A craterização excessiva enfraquece a aresta e pode levar à quebra da ferramenta, fator pelo qual a mesma deve ser monitorada.

CAPÍTULO V

CONCLUSÕES

Essa dissertação apresentou um estudo sobre classificação do desgaste de ferramentas de corte em operações de torneamento utilizando Técnicas de Inteligência Artificial.

A revisão bibliográfica e fundamentação teórica possibilitou a formação de uma sólida base de conhecimento facilitando o entendimento acerca dos fenômenos de desgaste, processo de torneamento, análise de vibração e Técnicas de Inteligência Artificial. Além disso, através da revisão bibliográfica pode-se confirmar o grande interesse de pesquisadores e empresas em relação ao tema, sendo um dos fatores motivadores da pesquisa.

A metodologia aplicada possibilitou utilizar dados experimentais reais e analisá-los de forma rápida e com baixo custo computacional, tornando a aplicação viável à realidade industrial.

Os resultados e discussões mostram a viabilidade de aplicar a Técnica de Inteligência Artificial W-KNN para classificação da condição de desgaste em ferramentas de corte.

5.1. Principais conclusões

As principais conclusões sobre o trabalho desenvolvido são apresentados a seguir.

- A Técnica de Inteligência Artificial W-KNN foi capaz de classificar a ferramenta em função da condição de desgaste ao utilizar os corretos parâmetros vibratórios. Neste trabalho a taxa de acerto foi de 97,1%.

- A metodologia desenvolvida pode ser aplicada à realidade industrial, reduzindo trocas de ferramentas desnecessárias e, conseqüentemente, aumentando a produção e evitando falhas catastróficas resultantes da quebra da ferramenta.

5.2. Conclusões secundárias

Além das principais conclusões supracitadas, pode-se destacar as conclusões apresentadas a seguir.

- O teste estatístico, Teste-t, de comparação das médias populacionais, mostrou ser uma boa ferramenta para identificação dos parâmetros que apresentam melhor correlação com o problema em estudo, o que foi confirmado através da análise dos Diagramas de Caixa (*Boxplot*).
- Comparando as Técnicas de Inteligência Artificial W-KNN, SVM e Rede SOM, para os mesmos parâmetros de entrada, a técnica W-KNN apresentou melhor resultado para os dados em estudo.
- A quantidade de 5 parâmetros apresentou melhor taxa de acerto para a técnica selecionada (W-KNN). Confirmou-se a máxima de que para Técnicas de Inteligência Artificial, com configurações próximas as estudadas, a utilização de um grande número de parâmetros somente contribui para o aumento do erro e do custo computacional.
- Os 5 parâmetros selecionados (Nível de energia do envelope filtrado com filtro passa banda entre 500 a 3 000 Hz; Nível de energia do envelope filtrado com filtro passa baixa em 3 000 Hz; Nível de energia do sinal filtrado com filtro passa baixa em 1 000 Hz; Nível de energia do sinal filtrado com filtro passa banda entre 500 a 3 000 Hz e Nível de energia do sinal filtrado com filtro passa baixa em 500 Hz) mostram que o nível de energia apresenta melhor correlação com a identificação do desgaste da ferramenta, sendo para o caso em estudo, na faixa de frequência de 0 a 3 000 Hz.
- Analisando a posição de fixação do sensor, verificou-se que a utilização do sensor somente na posição horizontal apresentou resultados superiores em relação a posição vertical e vertical e horizontal juntos. A análise da posição dos sensores é importante porque pode, como no caso em estudo, reduzir, significativamente o custo com

instrumentação. Recomenda-se para outras aplicações realizar uma análise modal a fim determinar a melhor posição.

- Em relação a configuração da técnica W-KNN, verificou-se que os melhores valores para a quantidade de número de vizinhos (k) foram: $k = 7, 10, 11$ e 12 . Visando a redução do custo computacional optou-se por trabalhar com $k = 7$.
- Conclui-se também a importância de utilizar um teste para verificação de valores extremos nas amostras em análise como, por exemplo, o Teste de Chauvenet. Essa verificação pode evitar possíveis problemas na indústria como falha de instrumentação, interferência externa, erros de ajuste e grande diferença de microestrutura dos materiais.
- Por fim, os resultados obtidos mostram que é possível determinar o momento ideal de troca da ferramenta tendo como base a condição de desgaste da mesma utilizando o sinal de vibração coletado com apenas um sensor. Por ser um método de medição indireto, não invasivo e de baixo custo, o mesmo se destaca perante outros métodos. Além disso, devido as características supracitadas, o método pode ser implementado em máquinas que já estão em operação, visto que, não são necessárias modificações na mesma, somente a fixação do acelerômetro.

5.3. Trabalhos futuros

Analisando a tendência dos parâmetros selecionados, nota-se que os mesmos apresentam um comportamento similar a uma distribuição de Weibull, a qual é muito utilizada no ramo estatístico para previsão de quebra e falhas de componentes.

Logo, propõe-se a continuação do desenvolvimento da metodologia apresentada nessa dissertação, utilizando a distribuição de Weibull. Dessa forma, acredita-se ser possível, além da identificação da condição de desgaste da ferramenta, prever de forma *on-line* o tempo que a mesma demorará para chegar em condição de falha.

Sugere-se também a aplicação da metodologia em uma linha de produção a fim de validar a eficiência da mesma.

REFERÊNCIAS BIBLIOGRÁFICAS

AFFONSO, G.S. Mapas Auto - organizáveis de Kohonen (SOM) aplicados na avaliação dos parâmetros da qualidade da água, São Paulo 2011. Dissertação (Mestrado)

AMARAL, R. P. F., BARBOSA, F. S., CURY, A. A., FONSECA, L. G., BONIFÁCIO, A. L. Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais. XII Simpósio de Mecânica Computacional At: Diamantina, May 2016.

BEZERRA, R. A. Detecção de Falhas em Rolamentos por Análise de Vibração. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas. 152 p. Tese (Doutorado), 2002.

BRITO, J. N. Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas. 214 p. Tese (Doutorado), 2002.

CÁRACH, J., HLOCH, S., PETRŮ, J., NAG, A., GOMBÁR, M., HROMASOVÁ, M.. Hydroabrasive disintegration of rotating Monel K-500 workpiece. The International Journal of Advanced Manufacturing Technology (2018) 96:981–1001 <https://doi.org/10.1007/s00170-018-1653-2>

CHAUVENET, W. A manual of spherical and practical astronomy, vol. II (5th ed., 1960). New York: Dover.

CHAVES, A.C.F. Extração de Regras Fuzzy para Máquinas de Vetor Suporte (SVM) para Classificação em Múltiplas Classes Rio de Janeiro, abril de 2006. Tese (Doutorado)

COVER, T. M., HART, P. E., Nearest neighbor pattern classification, IEEE Transactions on Information Theory, 13 (1), 1967, 21-27. <https://doi.org/10.1109/TIT.1967.1053964>

DA SILVA, R.H.L., DA SILVA, M.B., HASSUI, A., A probabilistic neural network applied in monitoring tool wear in the end milling operation via acoustic emission and cutting power signals, *Machining Science and Technology*, 2016, vol. 20, n 3, 386-405. <https://doi.org/10.1080/10910344.2016.1191026>

DIMLA., S. D. E. The Correlation of Vibration Signal Features to Cutting Tool Wear in a Metal Turning Operation. *Int J Adv Manuf Technol* (2002) 19:705–713. <https://doi.org/10.1007/s001700200080>

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. *Tecnologia da Usinagem Dos Materiais - 8ª 3a. Ed.* São Paulo: Artliber Editora, 2013

DUARTE, J.B. *Inteligência artificial aplicada no controle de qualidade em linhas de produção.* Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia. 95 p. Dissertação (Mestrado), 2013.

DUARTE, M. A. V., MEOLA, T., SOUSA, M. M., DA SILVA, M. B. Monitoramento do processo de furação em uma fresadora cnc utilizando sinais de vibração mecânica. II COBEF (Congresso Brasileiro de Engenharia de Fabricação), ABCM. Uberlândia, 2003.

DUDANI, S. A. The distance-weighted k-nearest neighbor rule, *IEEE Transactions on System, Man, and Cybernetics*, 6 (1976), 325-327. <https://doi.org/10.1109/TSMC.1976.5408784>

DROUILLET, C., KARANDIKAR J., NATH, C., JOURNEAUX, A., MANSORI, M., KURFESS, T. Tool life predictions in milling using spindle power with the neural network technique, *Journal of Manufacturing Processes* 22 (2016) 161–168. <https://doi.org/10.1016/j.jmapro.2016.03.010>

FERRARESI, D. *Fundamentos da Usinagem dos Metais.* Ed. Edgard Blucher, 1a ed. SP. 751p, 1990.

FIX, E., HODGES, J. L. Discriminatory Analysis, Nonparametric Discrimination: Consistency Properties, *Technique Report No. 4*, U. S. Air Force School of Aviation Medicine, Randolph Field Texas, 1951, 238-247

GOU, J., DU, L., ZHANG, Y., XIONG, T. A New Distance-weighted k-nearest Neighbor Classifier. *Journal of Information & Computational Science* 9: 6 (2012) 1429–1436

GROOVER, MIKELL P., Fundamentals of modern manufacturing: materials, processes and systems, 4th ed., United States, John Wiley & Sons, Inc. 2010.

HAYKIN, S. Neural networks: A comprehensive foundation. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd ed., 1998. ISBN 0132733501.

ISO 3685:1993(E), International Standard, Tool testing with single point turning tools.

KANNATEY-ASIBU, E., YUM, J., KIM, T. H. Monitoring tool wear using classifier fusion, Mechanical Systems and Signal Processing 85 (2017) 651–661. <https://doi.org/10.1016/j.ymsp.2016.08.035>

KOHONEN, T. Automatic formation of topological maps of patterns in a self-organizing system. In: Oja, E. e Simula, O., Eds. Proc. 2SCIA, Scand. Conf. on Image Analysis, p 214 – 220, Helsinki, Finland, 1981.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. Bi ol. Cybern.43, 59-69(1982). <https://doi.org/10.1007/BF00337288>

LAURO, C.H., BRANDÃO, L.C., BALDO, D., REIS, R.A., DAVIM, J.P. Monitoring and processing signal applied in machining processes – A review. Measurement 58 (2014) 73–86. <https://doi.org/10.1016/j.measurement.2014.08.035>

LIMA, C.R.A. Teoria de medidas: erros e gráficos. Ed.1, Juiz de Fora, Universidade Federal de Juiz de Fora, 2004.

LIU, C., LI, Y., HUA, J., LU, N., MOU, W. Real-time cutting tool state recognition approach based on machining features in NC machining process of complex structural parts, The International Journal of Advanced Manufacturing Technology (2018). <https://doi.org/10.1007/s00170-018-1916-y>

LIU, M., TAKAGI, J., TSUKUDA, A. Effect of tool nose radius and tool wear on residual stress distribution in hard turning of bearing steel, Journal of Materials Processing Technology, Volume 150, Issue 3, 20 July 2004, Pages 234-241. <https://doi.org/10.1016/j.jmatprotec.2004.02.038>

MACHADO, Á. R. et al. Teoria da usinagem dos materiais. 2a edição ed. São Paulo: Editora Blucher, 2011.

MEOLA, T. Proposta de uma metodologia baseada em análise modal operacional para monitoramento de fim de vida de ferramentas de corte. Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia. 95 p. Tese (Doutorado), 2009.

MIKOŁAJCZYK T., NOWICKI, K., BUSTILLO, A., YU PIMENOV, D. Predicting tool life in turning operations using neural networks and image processing, *Mechanical Systems and Signal Processing* 104 (2018) 503–513. <https://doi.org/10.1016/j.ymsp.2017.11.022>

NOURI, M., FUSSELL, B.K., ZINITI, B.L., LINDER, E. Real-time tool wear monitoring in milling using a cutting condition independent method, *International Journal of Machine Tools & Manufacture* 89 (2015) 1–13. <https://doi.org/10.1016/j.ijmachtools.2014.10.011>

RANDAL. B., ANTONI, J. Rolling element bearing diagnostics - A tutorial. *Mechanical Systems and Signal Processing*, Vol. 25 (2011) pag. 485-520

RAO, K.V., MURTHY, B.S.N., RAO, N.M., Cutting tool condition monitoring by analyzing surface roughness, work piece vibration and volume of metal removed for AISI 1040 steel in boring, *Measurement* 46 (10) (2013) 4075–4084. <https://doi.org/10.1016/j.measurement.2013.07.021>

REIS, D.A.S. Análise discriminante e otimização aplicadas ao controle de qualidade de ruído de compressores usando os softwares *r* e gurobi. Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia. 95 p. Dissertação (Mestrado), 2017.

RIZAL, M., GHANI, J.A., NUAWI, M.Z., HARON, C.H.C. Cutting tool wear classification and detection using multi-sensor signals and Mahalanobis-Taguchi System, *Wear* 376-377 (2017) 1759–1765. <https://doi.org/10.1016/j.wear.2017.02.017>

RMILI, W., OUAHABI, A., SERRA, R., LEROY, R. An automatic system based on vibratory analysis for cutting tool wear monitoring, *Measurement* 77 (2016) 117–123. <https://doi.org/10.1016/j.measurement.2015.09.010>

SILVA, V.A.D., Detecção de falhas em motores elétricos através das máquinas de vetores de suporte. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas. Dissertação (Mestrado), 2012.

SINGH, A., THAKUR N., SHARMA, A. A Review of Supervised Machine Learning Algorithms. 3rd International Conference on Computing for Sustainable Global Development. New Delhi, India (2016).

STEPHENSON, D. A.; AGAPIOU, J. S. Metal Cutting Theory and Practice. 3rd ed. Boca Raton, Florida. 999p, Taylor and Francis Group, 2016. <https://doi.org/10.1201/b19559>

TRENT, E. M.; WRIGHT, P. K. Metal cutting. 4. ed. Oxford: Butterworth- Heinemann, 2000.

VANZO, F. C. M. Metodologia para predição de tempo de falha de máquinas e equipamentos baseada no monitoramento de vibração. Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia. 149 p. Dissertação (Mestrado), 2017.

VAPNIK, V.N. The nature of statistical learning theory. Springer-Verlag New York, Inc., New York, NY, USA, 1995. ISBN 0-387-94559-8. <https://doi.org/10.1007/978-1-4757-2440-0>

VAPNIK, V.N, GOLOWICH, S.E., SMOLA, A. Support vector method for function approximation, regression estimation, and signal processing. In Advances in Neural Information Processing Systems 9, pp. 281–287. MIT Press, 1996.

VAPNIK, V.N., CHERVONENKIS, A.Y. On the uniform convergence of relative frequencies of events to their probabilities. Theory of Probability and its Applications, Vol. 16, no 2, 264–280, 1971. <https://doi.org/10.1137/1116025>

VITÓRIA, B. C. R. Análise do sinal de vibração no fresamento do aço AISI 4340 com ferramentas desgastadas. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica. Natal, RN, 2016.

WANG, C., CAJA, J., GÓMEZ, E. Comparison of methods for outlier identification in surface characterization, Measurement 117 (2018) 312–325. <https://doi.org/10.1016/j.measurement.2017.12.015>

WANG, G. F., YANG, Y.W., ZHANG, Y.C., XIE, Q.L. Vibration sensor based tool condition monitoring using v support vector machine and locality preserving projection. Sensors and Actuators, A: Physical, v. 209, p. 24–32, 2014. <https://doi.org/10.1016/j.sna.2014.01.004>

WU, X., YANG, J., WANG, S. Tea category identification based on optimal wavelet entropy and weighted k-Nearest Neighbors algorithm. *Multimed Tools Appl* (2018) 77:3745–3759. <https://doi.org/10.1007/s11042-016-3931-z>

YEN, C.L., LU, M.C., CHEN, J.L. Applying the self-organization feature map (SOM) algorithm to AE-based tool wear monitoring in micro-cutting, *Mechanical Systems and Signal Processing* 34 (2013) 353–366. <https://doi.org/10.1016/j.ymssp.2012.05.001>

YIGIT, H. A weighting approach for knn classifier. *International Conference on Electronics, Computer and Computation (ICECCO)*. Ankara, Turkey. 2013. <https://doi.org/10.1109/ICECCO.2013.6718270>

ZHANG, C., YAO, X., ZHANG, J., JIN, H. Tool Condition Monitoring and Remaining Useful Life Prognostic Based on a Wireless Sensor in Dry Milling Operations, *Sensors* (2016), 16(6), 795. <https://doi.org/10.3390/s16060795>

ZHOU, Y., XUE, W. Review of tool condition monitoring methods in milling processes, *The International Journal of Advanced Manufacturing Technology* (2018). <https://doi.org/10.1007/s00170-018-1768-5>

ANEXO I

ESPECIFICAÇÕES TÉCNICAS DOS EQUIPAMENTOS UTILIZADOS

I.1. Acelerômetro Brüel & Kjær 4397

- Temperatura máxima: 177 °C
- Referência de sensibilidade a: 50 Hz e 23 °C
- Sensibilidade - Sensor Vertical: 1,92 pC/m/s²
- Sensibilidade - Sensor Horizontal: 2,05 pC/m/s²
- Peso: 13 g
- Frequência natural não amortecida: 39 kHz
- Capacitância do cabo: 110 pF

I.2. Amplificador de carga Brüel & Kjær 2635

- Sensibilidade do amplificador: 0,01mV to 10V/pC correspondendo a -40 até +80dB
- Valores calibrados da saída:
 - Aceleração: 0,1 mV a 1 V/ms⁻²
 - Velocidade: 10 mV a 100 V/ms⁻¹
 - Deslocamento: 0,1 mV a 10 V/mm
- Faixa de frequência:
 - Aceleração: selecionável 0,2 ou 2,0 Hz até 100 kHz
 - Velocidade: selecionável 1,0 ou 10,0 Hz até 10 kHz
 - Deslocamento: selecionável 1,0 ou 10,0 Hz até 1 kHz

- Filtro de passa baixa: selecionável 10% limite de 100 Hz, 1 kHz, 3 kHz, 10 kHz, 30 kHz e > 100 kHz, com atenuação de declive 40 dB/decade.
- Peso: 1,45 kg

I.3. Placa de aquisição *National Instruments* NI USB-9162 | NI 9233

- Conexão: USB 2.0 Alta Velocidade
- Peso: 101 g
- Temperatura de operação: 0 a 60 °C
- Resolução: 24 bits
- Quantidade de canais: 4
- Faixa de medição: +- 5V

APÊNDICE I

ROTINAS UTILIZADA

Para o processo de usinagem uma rotina foi desenvolvida através do comando numérico do torno, apresentado a seguir.

N10 G21 G40 G90 G95;

N20 T1010;

N30 G0 X90 Z2;

N40 G96 S150;

N50 G92 S3 000 M3;

N60 G1 X82.9 F0.1;

N70 U-0.3;

N80 G1 W-34.6 F0.1;

N90 G0 U150;

N100 M0;

N110 G96 S150;

N120 G92 S3 000 M3;

N130 G0 U-149;

N140 G1 U-1 F0.05;

N150 G1 W-32.6 F0.1;

N160 G0 U150;

N160 M0;

N170 G96 S150;

N180 G92 S3 000 M3;

N190 G0 U-149;

N200 G1 U-1 F0.05;
N210 G1 W-32.6 F0.01;
N220 G0 U150;
N230 M0;
N240 G96 S150;
N250 G92 S300 M3;
N260 G0 U-150 W99.9;
N270 M99 P70;

Para coleta e análise dos sinais utilizou-se o algoritmo apresentado a seguir.

(1)

Iniciar coleta de vibração: posição vertical e horizontal.

Definir frequência de aquisição, 32768 Hz.

Tempo de coleta, 15 segundos.

Resolução em frequência (df) de 0,0667 Hz.

Salva o sinal.

(2)

Divide o sinal entre ferramentas em boas condições de uso e desgastadas.

Seleciona-se valores a serem utilizados para treinamento e validação.

(3)

Calcula-se os parâmetros vibratórios através das funções para:

- Domínio no tempo
- Análise de envelope
- Regiões do espectro

(4)

Inicia-se o Teste F-Snedecor

Define-se o tipo de Teste t a ser utilizado

Inicia-se o Teste t

Determina-se os maiores valores obtidos

(5)

Inicia-se o Classificador

Define-se os parâmetros do classificador

Executa o teste

Avalia o modelo

Fim

APÊNDICE II

MEDIÇÕES DE DESGASTE

Tabela A2.1 - Resultados dos testes para o Grupo I.

Teste	Desgaste V_{Bmax} (mm)	
	Inicial	Final
01	0,00000	0,09854
02	0,09854	0,09850
03	0,09850	0,10892
04	0,10892	0,11930
05	0,11930	0,13486
06	0,13486	0,14523
07	0,14523	0,15560
08	0,15560	0,17635
09	0,17635	0,19710
10	0,19710	0,20229
11	0,20229	0,21785
12	0,21785	0,22822
13	0,22822	0,25934
14	0,25934	0,27490
15	0,27490	0,28527
16	0,28527	0,29046

Tabela A2.1 - Resultados dos testes para o Grupo I (Continuação).

Teste	Desgaste V_{Bmax} (mm)	
	Inicial	Final
17	0,29046	0,31640
18	0,31640	0,33714
19	0,33714	0,35789
20	0,35789	0,36826
21	0,36826	0,37864
22	0,37864	0,40457
23	0,40457	0,42532
24	0,42532	0,43310
25	0,43310	0,45644
26	0,45644	0,46681
27	0,46681	0,48756
28	0,48756	0,50312
29	0,50312	0,51868
30	0,51868	0,52906

Fonte: Autor (2018).

Tabela A2.2 - Resultados dos testes para o Grupo II.

Teste	Ferramenta	Desgaste V_{Bmax} (mm)	
		Inicial	Final
1	F06A1	0	0,1193
2	F05A1	0	0,12967
3	F02A2	0	0,10892
4	F03A1	0	0,1193
5	F02A2	0,10892	0,12967
6	F05A1	0,12967	0,14004
7	F05A1	0,14004	0,16598
8	F02A2	0,12967	0,1556

Tabela A2.2 - Resultados dos testes para o Grupo II (Continuação).

Teste	Ferramenta	Desgaste V_{Bmax} (mm)	
		Inicial	Final
9	F04A1	0	0,11411
10	F06A1	0,1193	0,12448
11	F04A1	0,11411	0,12967
12	F03A1	0,1193	0,13486
13	F05A1	0,16598	0,17116
14	F06A1	0,12448	0,12967
15	F04A1	0,12967	0,13486
16	F05A1	0,17116	0,18673
17	F06A1	0,12967	0,1556
18	F06A1	0,1556	0,1556
19	F04A1	0,13486	0,15042
20	F05A1	0,18673	0,20229
21	F04A1	0,15042	0,1556
22	F03A1	0,13486	0,14782
23	F03A1	0,14782	0,15042
24	F03A1	0,15042	0,1556
25	F05A1	0,20229	0,21785
26	F02A2	0,1556	0,16079
27	F06A1	0,1556	0,16598
28	F03A1	0,1556	0,16857
29	F06A1	0,16598	0,18413
30	F02A2	0,16079	0,16598
31	F03A1	0,16857	0,17635
32	F03A1	0,17635	0,19191
33	F06A1	0,18413	0,21007
34	F03A1	0,19191	0,21007
35	F06A1	0,21007	0,21525

Tabela A2.2 - Resultados dos testes para o Grupo II (Continuação).

Teste	Ferramenta	Desgaste V_{Bmax} (mm)	
		Inicial	Final
36	F04A1	0,1556	0,17116
37	F04A1	0,17116	0,18154
38	F04A1	0,18154	0,18673
39	F05A1	0,21785	0,23859
40	F02A2	0,16598	0,18154
41	F03A1	0,21007	0,22822
42	F02A2	0,18154	0,18673
43	F02A2	0,18673	0,19191
44	F02A2	0,19191	0,20229
45	F02A2	0,20229	0,22563
46	F04A1	0,18673	0,19451
47	F05A1	0,23859	0,24897
48	F02A2	0,22563	0,25156
49	F02A2	0,25156	0,26193
50	F05A1	0,24897	0,26453
51	F06A1	0,21525	0,23341
52	F05A1	0,26453	0,28527
53	F02A2	0,26193	0,29565
54	F06A1	0,23341	0,236
55	F03A1	0,22822	0,23341
56	F06A1	0,236	0,25415
57	F02A2	0,29565	0,31121
58	F02A2	0,31121	0,33196
59	F04A1	0,19451	0,21785
60	F04A1	0,21785	0,22822
61	F04A1	0,22822	0,24119
62	F02A2	0,33196	0,33196

Tabela A2.2 - Resultados dos testes para o Grupo II (Continuação).

Teste	Ferramenta	Desgaste V_{Bmax} (mm)	
		Inicial	Final
63	F03A1	0,23341	0,23859
64	F06A1	0,25415	0,26971
65	F06A1	0,26971	0,26971
66	F03A1	0,23859	0,26193
67	F05A1	0,28527	0,30084
68	F05A1	0,30084	0,30862
69	F05A1	0,30862	0,32158
70	F02A2	0,33916	0,36308
71	F05A1	0,32158	0,33714
72	F06A1	0,26971	0,30602
73	F04A1	0,24119	0,24897
74	F04A1	0,24897	0,26453
75	F05A1	0,33714	0,3527
76	F06A1	0,30602	0,3138
77	F03A1	0,26193	0,26971
78	F02A2	0,36308	0,38901
79	F05A1	0,3527	0,37345
80	F03A1	0,26971	0,27231
81	F04A1	0,26453	0,28009
82	F06A1	0,3138	0,33196
83	F03A1	0,27231	0,30084
84	F06A1	0,33196	0,34233
85	F04A1	0,28009	0,28527
86	F03A1	0,30084	0,3164
87	F02A2	0,38901	0,3916
88	F02A2	0,3916	0,3942
89	F02A2	0,3942	0,40976

Tabela A2.2 - Resultados dos testes para o Grupo II (Continuação).

Teste	Ferramenta	Desgaste V_{Bmax} (mm)	
		Inicial	Final
90	F05A1	0,37345	0,38901
91	F02A2	0,40976	0,42013
92	F04A1	0,28527	0,31121
93	F03A1	0,3164	0,32677
94	F05A1	0,38901	0,40457
95	F04A1	0,31121	0,3164
96	F03A1	0,32677	0,3527
97	F06A1	0,34233	0,34752
98	F04A1	0,3164	0,33196
99	F05A1	0,40457	0,42532
100	F03A1	0,3527	0,35789
101	F05A1	0,42532	0,45125
102	F04A1	0,33192	0,3527
103	F04A1	0,3527	0,36308
104	F04A1	0,36308	0,36826
105	F05A1	0,45125	0,472
106	F06A1	0,34752	0,37604
107	F04A1	0,36826	0,3942
108	F05A1	0,472	0,48237
109	F02A2	0,42013	0,44607
110	F03A1	0,35789	0,36308
111	F05A1	0,48237	0,48756
112	F03A1	0,36308	0,37864
113	F04A1	0,3942	0,40457
114	F05A1	0,48756	0,49793
115	F03A1	0,37864	0,38901
116	F06A1	0,37604	0,3942
117	F03A1	0,38901	0,39679

Tabela A2.2 - Resultados dos testes para o Grupo II (Continuação).

Teste	Ferramenta	Desgaste $V_{B_{max}}$ (mm)	
		Inicial	Final
118	F02A2	0,44607	0,46681
119	F06A1	0,3942	0,39938
120	F06A1	0,39938	0,42013
121	F03A1	0,39679	0,40976
122	F04A1	0,40457	0,40976
123	F06A1	0,42013	0,42532
124	F02A2	0,46681	0,49275
125	F06A1	0,42532	0,44607

Fonte: Autor (2018).

APÊNDICE III

RESULTADOS TESTE DE HOMOCEASTICIDADE

Tabela A3.1 - Resultados do Teste F- Snedecor.

Parâmetro	Grupo 01 $F/F_{0.975.n_1-1.n_2-1}$			Grupo 02 $F/F_{0.975.n_1-1.n_2-1}$		
	Posição		Vertical e Horizontal	Posição		Vertical e Horizontal
	Vertical	Horizontal		Vertical	Horizontal	
1	0,266	51,233	0,575	2,007	29,691	0,789
2	1,807	0,39	0,660	0,358	0,497	0,632
3	2,504	1,070	0,650	2,831	0,014	0,847
4	0,761	0,205	0,266	0,832	4,183	1,190
5	0,673	0,208	0,629	0,843	4,107	1,176
6	0,850	0,295	0,858	0,718	9,138	1,305
7	0,723	0,241	0,396	0,921	2,633	0,930
8	2,374	1,060	0,665	2,325	0,016	0,719
9	2,675	2,746	1,129	1,048	1,244	1,234
10	1,024	0,686	1,160	0,835	0,860	0,830
11	0,570	0,408	1,232	0,696	0,838	0,726
12	0,639	0,434	1,322	0,688	0,851	0,758
13	0,852	0,589	1,349	0,690	0,830	0,934
14	0,970	1,255	0,522	0,726	0,864	0,830

Tabela A3.1 - Resultados do Teste F- Snedecor (Continuação).

Parâmetro	Grupo 01 $F/F_{0,975,n_1-1,n_2-1}$			Grupo 02 $F/F_{0,975,n_1-1,n_2-1}$		
	Posição		Vertical e Horizontal	Posição		Vertical e Horizontal
	Vertical	Horizontal		Vertical	Horizontal	
15	0,997	0,772	0,374	0,737	1,254	0,627
16	1,037	0,532	0,330	0,723	1,867	0,533
17	1,062	0,413	0,321	0,703	2,733	0,488
18	1,058	0,346	0,350	0,684	4,005	0,505
19	0,627	0,425	1,318	0,687	0,851	0,755
20	1,003	1,357	0,634	0,697	0,790	0,926
21	0,815	0,662	0,260	0,778	2,177	0,533
22	1,430	0,334	1,913	0,594	3,202	0,782
23	0,847	0,293	0,837	0,716	9,081	1,274
24	0,838	0,291	0,824	0,714	8,978	1,258
25	0,790	0,287	1,228	0,721	8,750	1,713
26	0,705	0,289	2,911	0,773	9,170	3,159
27	0,581	0,291	6,146	0,933	9,774	6,459
28	0,454	0,294	5,085	1,291	10,333	11,020
29	0,401	0,295	4,017	1,567	10,534	12,352
30	2,863	144,671	0,306	1,008	1,353	1,339
31	1,688	5,907	0,403	2,833	1,348	3,288
32	2,191	68,685	0,352	0,759	2,663	1,113
33	1,407	18,945	0,066	1,740	2,781	2,116
34	0,639	0,432	0,751	0,736	0,607	0,723
35	1,619	0,349	0,394	1,887	0,662	1,657
36	0,275	0,261	0,819	0,600	0,756	0,555
37	0,501	0,127	1,806	0,775	0,701	0,700
38	0,333	0,304	0,630	0,639	0,977	0,480
39	0,370	0,243	0,970	0,867	0,795	0,678

Tabela A3.1 - Resultados do Teste F- Snedecor (Continuação).

Parâmetro	Grupo 01 $F/F_{0,975,n_1-1,n_2-1}$			Grupo 02 $F/F_{0,975,n_1-1,n_2-1}$		
	Posição		Vertical e Horizontal	Posição		Vertical e Horizontal
	Vertical	Horizontal		Vertical	Horizontal	
40	0,931	0,640	1,064	0,613	0,869	1,025
41	2,434	1,092	0,651	2,106	1,089	2,174
42	0,839	1,640	0,434	0,754	1,148	0,852
43	1,108	2,505	0,409	1,699	1,419	1,199
44	1,017	1,069	0,342	0,744	1,552	0,660
45	1,554	0,978	0,338	1,453	1,632	0,839
46	1,126	0,591	0,313	0,714	2,033	0,534
47	1,869	0,532	0,283	1,318	2,195	0,679
48	1,098	0,387	0,334	0,694	3,351	0,493
49	1,712	0,314	0,269	1,232	3,055	0,666
50	0,247	0,254	0,819	0,594	0,752	0,556
51	0,325	0,134	2,017	0,666	0,686	0,677
52	1,058	0,576	1,253	0,588	0,878	0,981
53	1,306	0,656	0,821	1,984	0,984	2,006
54	0,786	1,284	0,283	0,817	2,121	0,658
55	1,054	1,228	0,322	0,808	1,908	0,571
56	1,430	0,334	1,913	0,594	3,202	0,782
57	0,861	0,280	1,247	0,706	2,476	0,812
58	0,852	0,294	0,846	0,716	9,055	1,285
59	0,779	0,242	0,421	1,064	3,858	1,045
60	0,845	0,291	0,779	0,713	8,928	1,194
61	0,770	0,241	0,374	0,982	4,058	0,950
62	0,814	0,287	0,862	0,702	8,039	1,331
63	0,572	0,263	0,598	0,536	3,557	0,891
64	0,775	0,289	2,869	0,695	8,558	2,784
65	0,831	0,254	1,429	0,464	3,554	1,679

Tabela A3.1 - Resultados do Teste F- Snedecor (Continuação).

Parâmetro	Grupo 01 $F/F_{0,975.n_1-1.n_2-1}$			Grupo 02 $F/F_{0,975.n_1-1.n_2-1}$		
	Posição			Posição		
	Vertical	Horizontal	Vertical e Horizontal	Vertical	Horizontal	Vertical e Horizontal
66	0,513	0,299	3,762	1,034	9,565	9,999
67	0,748	0,258	1,394	0,485	4,287	4,691
68	0,325	0,304	1,591	2,439	10,732	8,329
69	0,536	0,271	1,111	0,809	4,819	5,348
70	0,253	0,293	1,341	2,981	10,755	7,142
71	0,199	0,276	1,081	1,371	4,760	5,047

Fonte: Autor (2018).

APÊNDICE IV

RESULTADOS TESTE DE COMPARAÇÃO DAS MÉDIAS

Tabela A4.1 - Resultados do Teste t.

Parâmetro	Grupo 01 $t/t_{0.95.n}$			Grupo 02 $t/t_{0.95.n}$		
	Posição		Vertical e Horizontal	Posição		Vertical e Horizontal
	Vertical	Horizontal		Vertical	Horizontal	
1	4,865	0,727	1,302	4,158	0,891	0,604
2	1,630	1,887	4,310	4,810	0,957	2,934
3	2,548	1,817	1,683	0,829	1,661	1,021
4	0,301	2,920	2,359	3,293	3,881	1,078
5	0,144	3,129	1,868	3,481	3,961	1,168
6	0,260	3,275	1,773	2,895	4,123	1,416
7	0,092	2,861	2,466	3,490	4,043	1,031
8	2,559	1,813	1,685	0,999	1,635	1,143
9	1,775	0,885	10,960	5,223	7,657	6,376
10	1,279	0,420	10,937	7,830	9,206	8,405
11	0,386	0,016	10,836	8,971	9,680	9,063
12	0,362	0,113	10,631	8,992	9,929	9,282
13	0,544	0,385	9,806	8,583	10,363	9,392
14	0,593	0,316	6,397	6,993	9,476	5,950

Tabela A4.1 - Resultados do Teste t (Continuação).

Parâmetro	Grupo 01 $t/t_{0,95,n}$			Grupo 02 $t/t_{0,95,n}$		
	Posição		Vertical e Horizontal	Posição		Vertical e Horizontal
	Vertical	Horizontal		Vertical	Horizontal	
15	0,593	0,185	5,181	6,141	6,488	4,071
16	0,610	0,726	4,696	5,637	3,532	3,128
17	0,584	1,318	4,381	5,235	1,055	2,385
18	0,471	1,965	3,991	4,781	0,953	1,503
19	0,310	0,064	10,642	9,010	9,927	9,283
20	0,651	0,628	6,935	7,302	10,300	6,757
21	0,271	0,311	3,288	4,282	2,113	1,596
22	1,375	1,087	1,770	3,659	3,343	0,270
23	0,265	3,272	1,611	2,760	4,276	1,565
24	0,284	3,277	1,348	2,512	4,528	1,819
25	0,442	3,367	0,436	1,448	5,126	2,600
26	0,726	3,500	0,461	0,268	5,436	3,116
27	1,175	3,645	1,289	1,194	5,671	3,489
28	1,759	3,795	1,965	2,795	5,872	3,771
29	2,070	3,870	2,253	3,532	5,971	3,892
30	1,811	1,077	2,751	0,265	0,530	0,349
31	1,775	0,572	0,296	0,380	0,254	0,313
32	1,983	0,913	6,167	0,689	0,841	0,691
33	1,975	1,272	3,093	0,180	0,445	0,183
34	0,624	0,581	11,440	6,359	6,996	6,483
35	1,425	0,465	9,632	2,246	5,554	3,242
36	0,843	0,832	11,331	7,673	7,948	6,811
37	1,007	1,485	9,582	4,697	6,888	5,525
38	0,192	0,048	10,557	9,721	9,588	7,761
39	1,095	0,792	9,692	5,729	8,588	6,662

Tabela A4.1 - Resultados do Teste t (Continuação).

Parâmetro	Grupo 01 $t/t_{0,95,n}$			Grupo 02 $t/t_{0,95,n}$		
	Posição			Posição		
	Vertical	Horizontal	Vertical e Horizontal	Vertical	Horizontal	Vertical e Horizontal
40	0,731	1,181	8,744	8,241	10,735	8,645
41	1,087	1,463	9,267	4,085	9,128	5,404
42	0,402	1,271	5,265	6,537	9,472	4,729
43	1,290	2,045	6,542	3,785	7,193	3,594
44	0,650	0,922	4,529	5,806	6,878	3,348
45	1,623	1,911	5,625	3,889	5,012	2,753
46	0,833	0,221	4,445	5,518	3,719	2,856
47	1,727	0,638	5,557	4,094	2,701	2,431
48	0,714	1,020	4,181	5,015	0,159	2,016
49	1,471	0,899	5,408	3,635	0,098	1,635
50	1,019	0,964	11,339	7,679	7,926	6,814
51	1,456	1,554	9,637	5,188	6,703	5,716
52	0,950	1,249	9,255	8,351	10,794	8,931
53	0,863	1,488	9,938	4,455	9,319	5,774
54	0,029	1,242	3,162	3,875	4,081	1,625
55	0,450	1,377	3,946	4,496	3,657	1,773
56	1,375	1,087	1,770	3,659	3,343	0,270
57	1,829	1,900	1,962	4,211	3,143	0,080
58	0,258	3,271	1,711	2,853	4,172	1,463
59	0,163	2,866	2,471	2,788	4,360	1,278
60	0,260	3,259	1,463	2,663	4,431	1,693
61	0,058	2,848	2,311	2,850	4,454	1,320
62	0,352	3,298	0,682	1,573	5,132	2,532
63	0,539	3,169	1,413	2,981	4,952	1,908
64	0,542	3,425	0,416	0,367	5,440	3,098

Tabela A4.1 - Resultados do Teste t (Continuação).

Parâmetro	Grupo 01 $t/t_{0,95,n}$			Grupo 02 $t/t_{0,95,n}$		
	Posição			Posição		
	Vertical	Horizontal	Vertical e Horizontal	Vertical	Horizontal	Vertical e Horizontal
65	0,181	3,372	0,280	2,106	5,135	2,439
66	1,415	3,622	1,887	2,545	5,762	3,614
67	1,007	3,588	1,256	0,455	5,489	3,058
68	2,752	3,868	2,754	5,511	5,981	3,997
69	2,168	3,664	2,163	3,943	5,709	3,592
70	3,600	4,191	3,308	6,477	6,210	4,329
71	3,344	3,831	2,799	5,537	6,069	4,058

Fonte: Autor (2018).

APÊNDICE V

DETERMINAÇÃO DA QUANTIDADE DE PARÂMETROS DE ENTRADA E POSIÇÃO DO SENSOR

Tabela A5.1 - Resultados dos testes usando W-kNN - Posição Vertical e Horizontal.

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
01	1	84	79,1	87,5	85,0
	2	89,7	83,3	92,8	90,0
	3	88,7	83,3	92,8	90,0
	4	90,6	83,3	92,8	90,0
	5	90,1	79,1	87,5	85,0
	6	89,2	83,3	91,1	88,8
	7	88,7	83,3	89,2	87,5
	8	90,1	83,3	87,5	86,3
	9	87,8	83,3	92,8	88,8
	10	88,3	83,3	92,8	88,8
02	1	81,2	100	89,2	92,5
	2	85,4	95,8	92,8	93,8
	3	86,9	95,8	91,1	92,5

Tabela A5.1 - Resultados dos testes usando W-kNN - Posição Vertical e Horizontal (Continuação).

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
02	4	88,3	91,6	92,8	92,5
	5	88,7	95,8	89,2	91,3
	6	88,3	95,8	91,1	92,5
	7	90,1	95,8	91,1	92,5
	8	89,2	95,8	89,2	91,3
	9	87,3	95,8	92,8	93,8
	10	89,2	95,8	92,8	93,8
03	1	84	87,5	89,2	88,8
	2	88,7	83,3	94,6	91,3
	3	89,2	83,3	92,8	90,0
	4	89,7	83,3	94,6	91,3
	5	87,3	87,5	92,8	91,3
	6	90,6	87,5	94,6	92,5
	7	89,2	87,5	91,1	90,0
	8	90,1	87,5	92,8	91,3
	9	89,2	87,5	92,8	91,3
	10	89,2	87,5	92,8	91,3
04 Validação	1	83,5	-	89,2	89,2
	2	86,1	-	92,8	92,8
	3	87,3	-	92,8	92,8
	4	89	-	94,6	94,6
	5	90,3	-	92,8	92,8
	6	89	-	94,6	94,6
	7	89,5	-	92,8	92,8
	8	89,5	-	92,8	92,8
	9	89,9	-	92,8	92,8
	10	89,5	-	92,8	92,8

Fonte: Autor (2018).

Tabela A5.2 - Resultados dos testes usando W-kNN - Posição Horizontal.

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
01	1	87,6	100	89,2	92,1
	2	83,8	90	92,8	92,1
	3	88,6	90	92,8	92,1
	4	90,5	90	92,8	92,1
	5	90,5	90	96,4	94,7
	6	89,5	90	92,8	92,1
	7	91,4	90	89,2	89,5
	8	91,4	90	89,2	89,5
	9	91,4	90	89,2	89,5
	10	91,4	90	92,8	92,1
02	1	85,7	100	92,8	94,7
	2	82,9	100	92,8	94,7
	3	87,6	100	92,8	94,7
	4	87,6	100	92,8	94,7
	5	90,5	100	96,4	97,4
	6	90,5	100	96,4	97,4
	7	91,4	100	92,8	89,5
	8	89,5	100	92,8	89,5
	9	91,4	100	92,8	89,5
	10	90,5	100	92,8	94,7
03	1	84,8	90	89,2	89,5
	2	84,8	90	89,2	89,5
	3	87,6	90	89,2	89,5
	4	86,7	90	89,2	89,5
	5	88,6	90	89,2	89,5

Tabela A5.2 - Resultados dos testes usando W-kNN - Posição Horizontal (Continuação).

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
03	6	92,4	90	92,8	92,1
	7	90,5	90	89,2	89,5
	8	91,4	90	89,2	89,5
	9	91,4	90	85,7	86,8
	10	89,5	90	85,7	86,8
04 Validação	1	87,8	-	92,8	92,8
	2	85,2	-	92,8	92,8
	3	87,8	-	92,8	92,8
	4	89,6	-	92,8	92,8
	5	91,3	-	92,8	92,8
	6	92,2	-	96,4	96,4
	7	92,2	-	89,2	89,2
	8	91,3	-	89,2	89,2
	9	92,2	-	85,7	85,7
	10	92,2	-	92,8	92,8

Fonte: Autor (2018).

Tabela A5.3 - Resultados dos testes usando W-kNN - Posição Vertical.

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
01	1	88,2	66,6	85,7	80,0
	2	92,7	75,0	92,8	87,5

Tabela A5.3 - Resultados dos testes usando W-kNN - Posição Vertical (Continuação).

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)	
		Treinamento	Validação I	Validação II		
01	3	91,8	75,0	92,8	87,5	
	4	92,7	75,0	92,8	87,5	
	5	90,0	75,0	92,8	87,5	
	6	87,3	75,0	96,4	90,0	
	7	88,2	75,0	96,4	90,0	
	8	91,8	75,0	92,8	87,5	
	9	89,1	75,0	92,8	87,5	
	10	87,3	75,0	92,8	87,5	
	02	1	82,7	91,6	85,7	87,5
		2	90,9	91,6	92,8	92,5
3		91,8	83,3	92,8	90,0	
4		92,7	83,3	92,8	90,0	
5		90,0	83,3	92,8	90,0	
6		87,3	83,3	92,8	90,0	
7		90,0	91,6	92,8	92,5	
8		85,5	83,3	92,8	90,0	
9		86,4	83,3	92,8	90,0	
10		87,3	75,0	92,8	87,5	
03	1	84,5	66,6	85,7	80,0	
	2	90,9	91,6	92,8	92,5	
	3	90,9	83,3	92,8	90,0	
	4	88,2	83,3	92,8	90,0	
	5	87,3	83,3	92,8	90,0	
	6	88,2	91,6	92,8	92,5	
	7	89,1	91,6	96,4	95,0	
	8	84,5	91,6	92,8	92,5	

Tabela A5.3 - Resultados dos testes usando W-kNN - Posição Vertical (Continuação).

Subgrupo	Quantidade de Parâmetros	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
03	9	89,1	91,6	92,8	92,5
	10	85,5	91,6	92,8	92,5
04 Validação	1	84,4	-	85,7	85,7
	2	91,0	-	92,8	92,8
	3	92,6	-	92,8	92,8
	4	89,3	-	92,8	92,8
	5	85,2	-	92,8	92,8
	6	87,7	-	96,4	96,4
	7	87,7	-	96,4	96,4
	8	86,9	-	96,4	96,4
	9	87,7	-	96,4	96,4
	10	84,4	-	96,4	96,4

Fonte: Autor (2018).

Tabela A5.4 - Resumo dos resultados para as posições testadas.

Posição	Quantidade de Parâmetros	Taxa de Acerto (%)		
		Validação I	Validação II	Taxa de Acerto Final (Validação I + Validação II)
Vertical Horizontal	1	88,9	88,8	88,9
	2	87,5	93,3	91,9
	3	87,5	92,4	91,2
	4	86,1	93,8	91,9
	5	87,5	90,6	89,9
	6	88,9	92,9	91,9

Tabela A5.4 - Resumo dos resultados para as posições testadas (Continuação).

Posição	Quantidade de Parâmetros	Taxa de Acerto (%)		
		Validação I	Validação II	Taxa de Acerto Final (Validação I + Validação II)
	7	88,9	91,1	90,5
	8	88,9	90,6	90,2
	9	88,9	92,4	91,6
	10	88,9	92,4	91,6
Horizontal	1	96,7	91,1	92,3
	2	93,3	92,0	92,3
	3	93,3	92,0	92,3
	4	93,3	92,0	91,5
	5	93,3	93,8	93,7
	6	93,3	94,6	93,7
	7	93,3	88,4	88,7
	8	93,3	88,4	88,7
	9	93,3	86,6	88,0
	10	93,3	91,1	91,5
Vertical	1	75,0	85,7	83,1
	2	86,1	92,9	91,2
	3	80,6	92,9	89,9
	4	80,6	92,9	89,9
	5	80,6	92,9	89,9
	6	83,3	94,6	91,9
	7	86,1	95,5	93,2
	8	83,3	93,8	91,2
	9	83,3	93,8	91,2
	10	80,6	93,8	90,5

Fonte: Autor (2018).

APÊNDICE VI

DETERMINAÇÃO DA QUANTIDADE DE VIZINHOS PARA O MÉTODO W-kNN

Tabela A6.1 - Resultados dos testes em relação a quantidade de vizinhos para W-kNN.

Subgrupo	Quantidade de Vizinhos (k)	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
01	1	88,6	90,0	89,3	89,5
	2	88,6	90,0	89,3	89,5
	3	87,6	90,0	89,3	89,5
	4	88,6	90,0	89,3	89,5
	5	89,5	90,0	89,3	89,5
	6	87,6	90,0	89,3	89,5
	7	89,5	90,0	92,9	92,1
	8	88,6	90,0	92,9	92,1
	9	88,6	90,0	92,9	92,1
	10	89,5	90,0	96,4	94,7
	11	90,5	90,0	96,4	94,7
	12	90,5	90,0	96,4	94,7

Tabela A6.1 - Resultados dos testes em relação a quantidade de vizinhos para W-kNN (Continuação).

Subgrupo	Quantidade de Vizinhos (k)	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
01	13	89,5	90,0	96,4	94,7
	14	90,5	90,0	96,4	94,7
	15	90,5	90,0	96,4	94,7
	16	90,5	90,0	96,4	94,7
	17	90,5	90,0	92,9	92,1
	18	90,5	90,0	92,9	92,1
	19	90,5	90,0	92,9	92,1
	20	90,5	90,0	92,9	92,1
02	1	87,6	100,0	92,9	94,7
	2	88,6	100,0	92,9	94,7
	3	88,6	100,0	89,3	92,1
	4	85,7	100,0	89,3	92,1
	5	85,7	100,0	92,9	94,7
	6	86,7	100,0	92,9	94,7
	7	87,6	100,0	92,9	94,7
	8	86,7	100,0	96,4	97,4
	9	87,6	100,0	96,4	97,4
	10	87,6	100,0	96,4	97,4
	11	87,6	100,0	96,4	97,4
	12	87,6	100,0	96,4	97,4
	13	88,6	100,0	92,9	94,7
	14	87,6	100,0	92,9	94,7
	15	87,6	100,0	92,9	94,7

Tabela A6.1 - Resultados dos testes em relação a quantidade de vizinhos para W-kNN (Continuação).

Subgrupo	Quantidade de Vizinhos (k)	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
02	16	87,6	100,0	92,9	94,7
	17	87,6	100,0	92,9	94,7
	18	87,6	100,0	92,9	94,7
	19	87,6	100,0	92,9	94,7
	20	87,6	100,0	92,9	94,7
03	1	92,4	90,0	89,3	89,5
	2	89,5	90,0	89,3	89,5
	3	89,5	90,0	85,7	86,8
	4	90,5	90,0	85,7	86,8
	5	90,5	90,0	89,3	89,5
	6	89,5	90,0	92,9	92,1
	7	90,5	90,0	92,9	92,1
	8	91,4	90,0	89,3	89,5
	9	92,2	90,0	89,3	89,5
	10	92,2	90,0	89,3	89,5
	11	92,2	90,0	89,3	89,5
	12	92,2	90,0	89,3	89,5
	13	91,4	90,0	89,3	89,5
	14	90,5	90,0	89,3	89,5
	15	90,5	90,0	89,3	89,5
	16	90,5	90,0	89,3	89,5
	17	90,5	90,0	89,3	89,5
	18	90,5	90,0	89,3	89,5

Tabela A6.1 - Resultados dos testes em relação a quantidade de vizinhos para W-kNN (Continuação).

Subgrupo	Quantidade de Vizinhos (k)	Taxa de Acerto (%)			Taxa de Acerto Final (Validação I + Validação II)
		Treinamento	Validação I	Validação II	
03	19	90,5	90,0	89,3	89,5
	20	90,5	90,0	89,3	89,5
04	1	91,3		92,9	94,7
	2	91,3		92,9	94,7
	3	90,4		89,3	92,1
	4	90,4		89,3	92,1
	5	89,6		92,9	94,7
	6	90,4		96,4	97,4
	7	91,3		96,4	97,4
	8	91,3		92,9	94,7
	9	92,2		92,9	94,7
	10	91,3		92,9	94,7
	11	92,2		92,9	94,7
	12	92,2		92,9	94,7
	13	92,2		92,9	94,7
	14	92,2		92,9	94,7
	15	92,2		92,9	94,7
	16	92,2		92,9	94,7
	17	91,3		92,9	94,7
	18	91,3		92,9	94,7
	19	91,3		92,9	94,7
	20	91,1		92,9	94,7

Fonte: Autor (2018).

Tabela A6.2 - Resumo do resultados dos testes em relação a quantidade de vizinhos para W-kNN.

Quantidade de Vizinhos (k)	Taxa de Acerto (%)		
	Validação I	Validação II	Taxa de Acerto Final (Validação I + Validação II)
1	93,3	91,1	91,5
2	93,3	91,1	91,5
3	93,3	88,4	89,4
4	93,3	88,4	89,4
5	93,3	91,1	91,5
6	93,3	92,9	93,0
7	93,3	93,8	93,7
8	93,3	92,9	93,0
9	93,3	92,9	93,0
10	93,3	93,8	93,7
11	93,3	93,8	93,7
12	93,3	93,8	93,7
13	93,3	92,9	93,0
14	93,3	92,9	93,0
15	93,3	92,9	93,0
16	93,3	92,9	93,0
17	93,3	92,0	92,3
18	93,3	92,0	92,3
19	93,3	92,0	92,3
20	93,3	92,0	92,3

Fonte: Autor (2018).