

**UNESP – UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE BAURU
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

CESAR HENRIQUE ROSSINOLI MARTINS

**CLASSIFICAÇÃO DE NÍVEIS DE DESGASTE DE DRESSADORES DE PONTA
ÚNICA UTILIZANDO SINAIS DE EMISSÃO ACÚSTICA E REDES NEURAIIS
ARTIFICIAIS**

**Bauru
2013**

CESAR HENRIQUE ROSSINOLI MARTINS

**CLASSIFICAÇÃO DE NÍVEIS DE DESGASTE DE DRESSADORES DE PONTA
ÚNICA UTILIZANDO SINAIS DE EMISSÃO ACÚSTICA E REDES NEURAIIS
ARTIFICIAIS**

Dissertação apresentada à Faculdade de Engenharia de Bauru, como requisito para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Paulo Roberto de Aguiar

**Bauru
2013**

Martins, Cesar Henrique Rossinoli.

Classificação de níveis de desgaste de dressadores de ponta única utilizando sinais de emissão acústica e redes neurais artificiais / Cesar Henrique Rossinoli Martins, 2013

136 f.


Orientador: Prof. Dr. Paulo Roberto de Aguiar

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2013

1. Operação de dressagem. 2. Emissão acústica. 3. Redes neurais artificiais. 4. MLP. 5. Rede de Kohonen. 6. Desgaste de dressadores. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE CESAR HENRIQUE ROSSINOLI MARTINS, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO(A) FACULDADE DE ENGENHARIA DE BAURU.

Aos 20 dias do mês de março do ano de 2013, às 10:00 horas, no(a) ANFITEATRO DA SEÇÃO TÉCNICA DE PÓS-GRADUAÇÃO DA FACULDADE DE ENGENHARIA DE BAURU, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. PAULO ROBERTO DE AGUIAR do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. ROGÉRIO ANDRADE FLAUZINO do(a) Departamento de Engenharia Elétrica e de Computação / Escola de Engenharia de São Carlos - USP, Prof. Dr. JOSE ALFREDO COVOLAN ULSON do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de CESAR HENRIQUE ROSSINOLI MARTINS, intitulado "CLASSIFICAÇÃO DE NÍVEIS DE DESGASTE DE DRESSADORES DE PONTA ÚNICA UTILIZANDO MODELOS NEURAIIS". Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: Aprovado. Nada mais havendo, foi lavrada a presente ata, que, após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.


Prof. Dr. PAULO ROBERTO DE AGUIAR


Prof. Dr. ROGÉRIO ANDRADE FLAUZINO


Prof. Dr. JOSE ALFREDO COVOLAN ULSON



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Bauru



PROPOSTA DE ALTERAÇÃO DO TÍTULO


A BANCA EXAMINADORA PROPÕE A ALTERAÇÃO DO TÍTULO DO TRABALHO DO ALUNO:
CÉSAR HENRIQUE ROSSINOLI MARTINS

DE: "CLASSIFICAÇÃO DE NÍVEIS DE DESGASTE DE DRESSADORES DE PONTA ÚNICA
UTILIZANDO MODELOS NEURAIIS"

PARA:

Classificação de Níveis de Desgaste de Dressadores
de Ponta Única Utilizando Sinais de Emissão
Acústica e Redes Neurais Artificiais

Bauru, 20 de março de 2013.


Prof. Dr. Paulo Roberto de Aguiar
Orientador

Dedico a minha familia que me apoia em
minhas escolhas.

AGRADECIMENTOS

Aos meus pais Antonio José Farinha Martins e Sandra Regina Rossino Martins por todo apoio e condições que me foram proporcionadas. Aos meus irmãos Lucas José Rossinoli Martins, Caroline Rossinoli e Gabriel Rossinoli Martins pela compreensão, amizade e companheirismo.

Ao Professor Titular Paulo Roberto de Aguiar pela chance, confiança e orientação durante esses dois anos de pesquisa.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica e Engenharia Mecânica de do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Bauru - UNESP, pelo conhecimento transmitido.

Aos alunos de iniciação científica Arminio Frech Junior, Flávio Chavaglia e Rodrigo Ruzzi pela disposição em auxiliarem na execução dos ensaios e avaliação do desgaste dos dressadores.

Aos amigos do curso de mestrado e do Laboratório de Aquisição de Dados - LADAPS, Maurício Eiji Nakai, Marcelo Marchi, Daniela Fernanda Moia, Hildo Guillard Junior, Hugo Iouchan e Thiago Matheus Gerônimo pela amizade, contribuições e apoio.

Aos meus amigos que de alguma forma estiveram presentes nessa caminhada.

O homem para o qual o sentimento do mistério não é familiar, que perdeu a faculdade de se encantar, se aprofundar no respeito é um homem morto.

- Albert Einstein.

RESUMO

A retificação é um processo de acabamento de peças, que objetiva produtos e superfícies avançadas. Porém, com o constante atrito entre a peça e rebolo, este perde a agressividade, de modo que o resultado da retificação fica prejudicado. Quando isso ocorre é imprescindível à realização do processo de dressagem, que consiste em reavivar os grãos gastos do rebolo. Como as condições de dressagem provocam uma grande influência no desempenho da operação de retificação, monitorá-las durante todo o processo pode aumentar a sua eficiência. Assim, no presente trabalho foi realizado um estudo do desgaste de três tipos de diamantes para dressadores e, posteriormente, foram desenvolvidos modelos neurais, baseados em redes MLP e de Kohonen, capazes de classificar o nível de desgaste dos dressadores. Para se atingir esse objetivo foram ensaiados três tipos de dressadores de ponta única, um com diamante sintético CVD e dois com diamantes naturais, Mato Grosso e Brasil Extra. Serviram de entradas para os modelos neurais as estatísticas RMS e ROP obtidas após o estudo do conteúdo harmônico do sinal de emissão acústica. Para cada diamante foi obtido um modelo neural mais apto para as características do diamante. Os resultados mostraram um bom desempenho das redes neurais empregadas, atingindo-se taxas de acerto de 100% em alguns modelos neurais.

Palavras chave: operação de dressagem, emissão acústica, redes neurais artificiais, perceptron de múltiplas camadas, desgaste de dressadores.

ABSTRACT

Grinding is a part finishing process for advanced products and surfaces. However, continuous friction between the work piece and the grinding wheel causes the latter to lose its sharpness, thus impairing the grinding results. This is when the dressing process is required, which consist of sharpening the worn grains of the grinding wheel. The dressing conditions strongly affect the performance of the grinding operation; hence, monitoring them throughout the process can increase its efficiency. The main objective of this study was to classify the levels of wear of a single-point dresser during the operation using neural models. A digital signal processing of acoustic emission was used to obtain the network inputs. In the experiments three types of single-point dresser were used, one with CVD synthetic diamond and two with natural diamonds, Mato Grosso and Brasil Extra. The harmonic content of the acoustic emission signal was found to be influenced by the condition of the dresser, and when used to feed the neural model it is possible to classify the wear level. The results showed a good performance of the neural networks employed, reaching a hit rate of 100% for some models.

Key words: dressing operation, acoustic emission, neural network, multilayer perceptron, dresser wear.

SUMÁRIO

Capítulo 1 - Introdução, Objetivos e Publicações	1
1.1 Introdução	1
1.2 Objetivo.....	2
1.3 Publicações Relacionadas	2
Capítulo 2 - Revisão Bibliográfica	4
2.1 O Processo de Retificação	4
2.1.1 Parâmetros na retificação plana.....	5
2.1.2 Forças de corte no processo de retificação	8
2.1.3 Potência na retificação.....	9
2.1.4 rugosidade das peças retificadas.....	9
2.2 Rebolo	10
2.2.1 Grãos abrasivos.....	10
2.2.2 Ligantes	10
2.2.3 Dureza.....	11
2.2.4 Granulometria.....	11
2.2.5 Estrutura.....	12
2.3 A Operação de Dressagem.....	12
2.3.1 Dressagem e Topografia.....	12
2.3.2 Dressador de ponta única.....	13
2.4 Diamantes para Dressadores	15
2.4.1 Diamantes Sintéticos - CVD.....	15
2.5 Monitoramento do Processo de Retificação	16
2.6 Emissão Acústica	17
2.7 Processamento de Sinais	17
2.7.1 Valor Eficaz de um Sinal (RMS).....	18
2.7.2 Taxa de potência de um Sinal (ROP)	18
2.7.3 Transformada Discreta de Fourier (DFT).....	19
2.7.4 Média e Desvio Padrão.....	19
2.8 Redes Neurais Artificiais (RNA)	20
2.8.1 Rede Neural <i>Perceptron</i> de Múltiplas Camadas	22
2.8.2 Rede Neural de Kohonen.....	24
Capítulo 3 - Materiais e Métodos	28
3.1 Montagem do Banco de Ensaios.....	28
3.1.1 Configuração dos Parâmetros de Dressagem	29
3.1.2 Sistema de Aquisição de Imagens	30
3.1.3 Sistema de Aquisição de Dados.....	31

3.2	Procedimentos dos Ensaios	31
3.3	Aquisição dos Dados de Desgaste do Dressador.....	32
3.4	processamento do Sinal de Emissão Acústica.....	32
3.5	Modelos Neurais.....	34
3.5.1	Treinamento dos Modelos Neurais	35
Capítulo 4 - Resultados e Discussões		37
4.1	Desgaste dos Diamantes	37
4.1.1	Diamante CVD.....	37
4.1.2	Diamante Mato Grosso	42
4.1.3	Diamante Brasil Extra.....	46
4.1.4	Comparações entre os Três Diamantes	51
4.2	Processamento do Sinal de Emissão Acústica	53
4.2.1	Análise do Valor Médio RMS	54
4.2.2	Estudo do Espectro de Frequência do Sinal de EA.....	57
4.3	Modelos Neurais.....	64
4.3.1	Grupo 1: Rede Neural MLP de Nove Entradas.....	64
4.3.2	Grupo 2: Rede Neural MLP de Duas Entradas.....	70
4.3.3	Grupo 3: Rede Neural MLP de Quatro Entradas	79
4.3.4	Grupo 4: Rede Neural de Kohonen de Nove Entradas	82
4.3.5	Grupo 5: Rede Neural de Kohonen de Duas Entradas.....	87
4.3.6	Grupo 6: Rede Neural de Kohonen de Quatro Entradas.....	96
4.3.7	Comparação entre os Modelos Neurais	99
Capítulo 5 - Conclusão.....		103
5.1	Sugestões para os Próximos Trabalhos	104
Referências.....		105

LISTA DE ILUSTRAÇÕES

Figura 1 - Operações básicas na retificação, adaptado (MARINESCU, HITCHINER, <i>et al.</i> , 2007).....	5
Figura 2 - Esquema dos parâmetros: velocidade do rebolo V_s ; velocidade da peça V_w ; profundidade de corte a ; comprimento de contato l_c . Adaptado (MALKIN, 1989).....	6
Figura 3 - Componentes de força para retificação tangencial plana, adaptado (MALKIN, 1989).....	8
Figura 4 - Representação esquemática do processo de dressagem, adaptado (OLIVEIRA e BIANCHI, 1992).	14
Figura 5 - Modelo de neurônio biológico, adaptado (NEGNEVITSKY, 2005).....	21
Figura 6 - Modelo do neurônio artificial (HAYKIN, 1999).....	21
Figura 7 - Exemplo de uma rede MLP (DYMINSKI, 2000).....	23
Figura 8 - Estrutura básica de uma rede neural de Kohonen.	25
Figura 9 – Exemplo de mapa de contexto de três classe.	26
Figura 10 – Estrutura neural básica de uma rede competitiva (SILVA, SPATTI e FLAUZINO, 2010).....	26
Figura 11 - Formato dos dressadores utilizados, no detalhe ponta de diamante.	28
Figura 12 - Esquema da montagem do banco de ensaios.	29
Figura 13 - Sistema de aquisição de imagens: (a) microscópio estereoscópio com a câmera acoplada; (b) câmera EC 3 em detalhe.....	30
Figura 14 - Vistas da ponta do resador: (a) lateral; (b) frontal.	31
Figura 15 - Evolução do desgaste do dressador CVD - (a) vista lateral. (b) vista frontal.....	32
Figura 16 - Sinal puro (a) e sinal RMS (b) de EA para uma passada do ensaio do dressador CVD.	33
Figura 17 - Passada com contato consistente (a); Passada com contato incompleto (b).	33
Figura 18 - Processo de tratamento do sinal de EA.....	34
Figura 19 - Fluxograma do algoritmo de teste dos modelos neurais.....	36
Figura 20 - Área desgasta por quantidade de passadas para o diamante CVD, para vista lateral.....	39

Figura 21 - Área desgasta por quantidade de passadas para o diamante CVD, para vista frontal.....	41
Figura 22 - Área desgastada por passada para o diamante Mato Grosso, para vista lateral.....	43
Figura 23 - Área desgastada por passada para o diamante Mato Grosso, para vista frontal.....	45
Figura 24 - Área desgastada por passada para o diamante Brasil Extra, para vista lateral.....	48
Figura 25 - Área desgastada por passada para o diamante Brasil Extra, para vista frontal.....	50
Figura 26 - Área desgastada por número da passada para os três diamantes, para vista lateral.....	52
Figura 27 - Área desgastada por número da passada para os três diamantes, para vista frontal.....	53
Figura 28 - Identificação da passada. (a) Sinal puro; (b) Sinal RMS com destaque da passada válida.....	54
Figura 29 - Valores médios RMS para o dressador do tipo CVD. (a) Ensaio 01; (b) Ensaio 02; (c) Ensaio 03; (d) Média do dressador.....	55
Figura 30 - Valores médios RMS para o dressador do tipo Mato Grosso. (a) Ensaio 01; (b) Ensaio 02; (c) Ensaio 03; (d) Média do dressador.....	55
Figura 31 - Valores médios RMS para o dressador do tipo Brasil Extra. (a) Ensaio 01; (b) Ensaio 02; (c) Ensaio 03; (d) Média do dressador.....	56
Figura 32 – Esquema de montagem para o teste da fratura do grafite do sensor de EA.....	57
Figura 33 – Sinal puro do impulso para: (a) Teste 1; (b) Teste 2; (c) Teste 3.....	58
Figura 34 – Sinal RMS do impulso para: (a) Teste 1; (b) Teste 2; (c) Teste 3.....	58
Figura 35 – Resposta em frequência do sensor de EA.....	59
Figura 36 - Espectro de frequência dos três níveis de desgaste do dressador CVD. ...	60
Figura 37 - Espectro de frequência dos três níveis de desgaste dos dressadores: (a) Mato Grosso; (b) Brasil Extra.....	60
Figura 38 - Espectro de frequência com as bandas destacadas. (a) Dressador CVD; (b) Dressador Mato Grosso; (c) Dressador Brasil Extra.....	61

Figura 39 - Valores médios RMS em função das bandas de frequência para os dressadores:	63
Figura 40 - Valores médio ROP em função das bandas de frequência para os dressadores:	64
Figura 41 - Estrutura geral dos modelos neurais do Grupo 1.....	65
Figura 42 - Matriz de confusão dos modelos: (a) Modelo 1; (b) Modelo 2; (c) Modelo 3.....	67
Figura 43 - Matriz de confusão dos modelos: (a) Modelo 4; (b) Modelo 5; (c) Modelo 6.....	67
Figura 44 - Classificação das passadas do ensaio CVD realizada pelo Modelo 1.	68
Figura 45 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 2.....	68
Figura 46 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 3.	69
Figura 47 - Classificação das passadas do ensaio CVD realizada pelo Modelo 4.	69
Figura 48 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 5.....	69
Figura 49 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 6.	70
Figura 50 - Estrutura geral dos modelos neurais do Grupo 2.....	70
Figura 51 - Resultados do Modelo 7. (a) Matriz de confusão; (b) Regiões de classificação.....	72
Figura 52 - Resultados do Modelo 8. (a) Matriz de confusão; (b) Regiões de classificação.....	73
Figura 53 - Resultados do Modelo 9. (a) Matriz de confusão; (b) Regiões de classificação.....	73
Figura 54 - Resultados do Modelo 10. (a) Matriz de confusão; (b) Regiões de classificação.....	73
Figura 55 - Resultados do Modelo 11. (a) Matriz de confusão; (b) Regiões de classificação.....	74
Figura 56 - Resultados do Modelo 12. (a) Matriz de confusão; (b) Regiões de classificação.....	74

Figura 57 - Resultados do Modelo 13. (a) Matriz de confusão; (b) Regiões de classificação.	74
Figura 58 - Resultados do Modelo 14. (a) Matriz de confusão; (b) Regiões de classificação.	75
Figura 59 - Resultados do Modelo 15. (a) Matriz de confusão; (b) Regiões de classificação.	75
Figura 60 - Classificação das passadas do ensaio CVD realizada pelo Modelo 7.....	76
Figura 61 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 8.....	76
Figura 62 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 9.	76
Figura 63 - Classificação das passadas do ensaio CVD realizada pelo Modelo 10.....	77
Figura 64 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 11.....	77
Figura 65 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 12.....	77
Figura 66 - Classificação das passadas do ensaio CVD realizada pelo Modelo 13.....	78
Figura 67 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 14.....	78
Figura 68 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 15.....	78
Figura 69 - Estrutura geral dos modelos neurais do Grupo 3.	79
Figura 70 - Resultados do Modelo 16. (a) Matriz de confusão; (b) Regiões de classificação.	80
Figura 71 - Resultados do Modelo 17. (a) Matriz de confusão; (b) Regiões de classificação.	80
Figura 72 - Resultados do Modelo 18. (a) Matriz de confusão; (b) Regiões de classificação.	81
Figura 73 - Classificação das passadas do ensaio CVD realizada pelo Modelo 16.....	81
Figura 74 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 17.....	82
Figura 75 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 18.....	82

Figura 76 - Matriz de confusão dos modelos: (a) Modelo 19; (b) Modelo 20; (c) Modelo 21.....	84
Figura 77 - Matriz de confusão dos modelos: (a) Modelo 22; (b) Modelo 23; (c) Modelo 24.....	84
Figura 78 - Classificação das passadas do ensaio CVD realizada pelo Modelo 19.	85
Figura 79 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 20.....	85
Figura 80 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 21.....	86
Figura 81 - Classificação das passadas do ensaio CVD realizada pelo Modelo 22.	86
Figura 82 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 23.....	86
Figura 83 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 24.....	87
Figura 84 - Resultados do Modelo 25. (a) Matriz de confusão; (b) Regiões de classificação.....	89
Figura 85 - Resultados do Modelo 26. (a) Matriz de confusão; (b) Regiões de classificação.....	89
Figura 86 - Resultados do Modelo 27. (a) Matriz de confusão; (b) Regiões de classificação.....	90
Figura 87 - Resultados do Modelo 28. (a) Matriz de confusão; (b) Regiões de classificação.....	90
Figura 88 - Resultados do Modelo 29. (a) Matriz de confusão; (b) Regiões de classificação.....	90
Figura 89 - Resultados do Modelo 30. (a) Matriz de confusão; (b) Regiões de classificação.....	91
Figura 90 - Resultados do Modelo 31. (a) Matriz de confusão; (b) Regiões de classificação.....	91
Figura 91 - Resultados do Modelo 32. (a) Matriz de confusão; (b) Regiões de classificação.....	91
Figura 92 - Resultados do Modelo 33. (a) Matriz de confusão; (b) Regiões de classificação.....	92
Figura 93 - Classificação das passadas do ensaio CVD realizada pelo Modelo 25.	93

26.....	Figura 94 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo	93
27.....	Figura 95 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo	93
	Figura 96 - Classificação das passadas do ensaio CVD realizada pelo Modelo 28.....	94
29.....	Figura 97 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo	94
30.....	Figura 98 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo	94
	Figura 99 - Classificação das passadas do ensaio CVD realizada pelo Modelo 31.....	95
32.....	Figura 100 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo	95
33.....	Figura 101 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo	95
	Figura 102 - Resultados do Modelo 34. (a) Matriz de confusão; (b) Regiões de classificação.....	97
	Figura 103 - Resultados do Modelo 35. (a) Matriz de confusão; (b) Regiões de classificação.....	97
	Figura 104 - Resultados do Modelo 36. (a) Matriz de confusão; (b) Regiões de classificação.....	97
	Figura 105 - Classificação das passadas do ensaio CVD realizada pelo Modelo 34... 98	
35.....	Figura 106 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo	98
36.....	Figura 107 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo	99

LISTA DE TABELAS

Tabela 1 - Características dos dressadores utilizados.....	28
Tabela 2 - Parâmetros de dressagem empregados nos ensaios.....	30
Tabela 3 - Parâmetros de configuração do sistema de aquisição de dados.	31
Tabela 4 - Parâmetros de configuração da rede neural MLP.	35
Tabela 5 - Parâmetros de configuração da rede neural de Kohonen.	35
Tabela 6 - Dados de área desgastada obtidos para os ensaios dos diamantes CVD a partir da vista lateral.	37
Tabela 7 - Área desgastada média do diamante CVD, para vista lateral.....	38
Tabela 8 - Imagens de referência para o cálculo da área desgastada do diamante CVD , para vista lateral.....	38
Tabela 9 - Dados de área desgastada obtidos para os ensaios dos diamantes CVD a partir da vista frontal.....	40
Tabela 10 - Área desgastada média do diamante CVD, para vista frontal.....	40
Tabela 11 - Imagens de referência para o cálculo da área desgastada do diamante CVD , para vista frontal.	41
Tabela 12 - Dados de área desgastada obtidos para os ensaios dos diamantes Mato Grosso, para vista lateral.	42
Tabela 13 - Área desgastada média do diamante Mato Grosso, para vista lateral.	43
Tabela 14 - Imagens de referência para o cálculo da área desgastada do diamante Mato Grosso, para vista lateral.	44
Tabela 15 - Dados de área desgastada obtidos para os ensaios dos diamantes Mato Grosso, para vista frontal.....	45
Tabela 16 - Área desgastada média do diamante Mato Grosso, para vista frontal.....	45
Tabela 17 - Imagens de referência para o cálculo da área desgastada do diamante Mato Grosso, para vista frontal.....	46
Tabela 18 - Dados de área desgastada obtidos para os ensaios dos diamantes Brasil Extra, para vista lateral.	47
Tabela 19 - Área desgastada média do diamante Brasil Extra, para vista lateral.....	47
Tabela 20 -Imagens de referência para o cálculo da área desgastada do diamante Brasil Extra, para vista lateral.	48

Tabela 21 - Dados de área desgastada obtidos para os ensaios dos diamantes Brasil Extra, para vista frontal.....	49
Tabela 22 - Área desgastada média do diamante Brasil Extra, para vista frontal.....	49
Tabela 23 - Imagens de referência para o cálculo da área desgastada do diamante Brasil Extra, para vista frontal.	50
Tabela 24 - Dados de desgaste da vista lateral para os três diamantes.	51
Tabela 25 - Dados de desgaste da vista frontal para os três dressadores.....	52
Tabela 26 - Bandas de frequência consideradas para estudo.	61
Tabela 27 - Parâmetros dos modelos neurais do Grupo 1 - RMS.....	65
Tabela 28 - Parâmetros dos modelos neurais do Grupo 1 - ROP.	66
Tabela 29 - Parâmetros dos modelos neurais do Grupo 2 - RMS.....	71
Tabela 30 - Parâmetros dos modelos neurais do Grupo 2 - ROP.	71
Tabela 31 - Parâmetros dos modelos neurais do Grupo 2 - RMS/ROP.....	71
Tabela 32 - Parâmetros dos modelos neurais do Grupo 3 - RMS/ROP.....	79
Tabela 33 - Parâmetros dos modelos neurais do Grupo 4 - RMS.....	83
Tabela 34 - Parâmetros dos modelos neurais do Grupo 4 - ROP.	83
Tabela 35 - Parâmetros dos modelos neurais do Grupo 5 - RMS.....	88
Tabela 36 - Parâmetros dos modelos neurais do Grupo 5 - ROP.	88
Tabela 37 - Parâmetros dos modelos neurais do Grupo 5 - RMS/ROP.....	88
Tabela 38 - Parâmetros dos modelos neurais do Grupo 6 - RMS/ROP.....	96
Tabela 39 - Valores de erro médio dos modelos neurais MLP.....	100
Tabela 40 - Valores de erro médio dos modelos neurais de Kohonen.....	101

LISTA DE ABREVIATURAS E SIGLAS

<i>a</i> : profundidade de corte.	mm
<i>V_S</i> : velocidade de corte.	m/s
<i>V_W</i> : velocidade da peça.	m/s
<i>l_C</i> : comprimento de contato.	mm
<i>Q'_w</i> : taxa específica de remoção de material.	mm/s
<i>h_{eq}</i> : espessura equivalente de corte.	μm
<i>F_t</i> : força tangencial de corte.	N
<i>P</i> : potência.	W
<i>s_d</i> : avanço de dressagem.	mm
<i>v_d</i> : velocidade de dressagem.	mm/s
<i>b_d</i> : largura útil do dressador.	mm
<i>U_d</i> : grau de recobrimento.	
<i>σ</i> : desvio padrão.	
<i>\bar{x}</i> : média aritmética.	
<i>EA</i> : emissão acústica.	V
<i>RMS</i> : root mean square.	
<i>ROP</i> : ratio of power.	
<i>DFT</i> : transformada discreta de Fourier.	
<i>FFT</i> : transformada rápida de Fourier.	
<i>RNA</i> : rede neural artificial.	
<i>MLP</i> : perceptron de múltiplas camadas.	
<i>BF</i> : banda de frequência.	
<i>N</i> : dressador novo.	
<i>MV</i> : dressador com meia vida.	
<i>D</i> : dressador desgastado.	

CAPITULO 1 - INTRODUÇÃO, OBJETIVOS E PUBLICAÇÕES

1.1 INTRODUÇÃO

O processo de retificação é empregado com o objetivo de se obter um melhor acabamento nas peças usinadas, alcançando produtos e superfícies avançadas de alta precisão. O desempenho deste processo está estritamente relacionado às condições da ferramenta de corte utilizada, o rebolo, de tal forma que o uso dessa ferramenta fora das condições ideais pode danificar a peça. Através da operação de dressagem é possível recondicionar o rebolo, garantindo assim o sucesso do processo de usinagem (LEE, HWANG e DORNFELD, 2004) (HASSUI, DINIZ, *et al.*, 1998).

Sendo a dressagem um processo transformador da superfície do rebolo é importante se conhecer bem o processo, já que se variando as condições de dressagem as forças de retificação podem variar em cerca de 500% (OLIVEIRA, COELHO, *et al.*, 2000) (OLIVEIRA, SILVA e BIFFI, 2002). Além dos parâmetros de dressagem o desgaste do diamante do dressador também afeta a superfície retificada. De modo que, um dressador desgastado pode proporcionar uma menor agressividade ao rebolo, aumentando assim as forças de corte e, conseqüentemente, causando a queima da peça retificada (PORZYCKI, 2005) (VERKERK, 1976) (OLIVEIRA, SILVA e BIFFI, 2002).

Como o desgaste da ferramenta influencia de forma negativa a qualidade do trabalho, e a quebra da mesma correspondem em cerca de 20% do tempo de máquina parada, tem crescido a atenção dada a este problema. Nesse contexto, realizar o monitoramento do desgaste da ferramenta é importante para se obter um processo mais confiável e reduzir os custos do mesmo (LIANG, HECKER e LANDERS, 2004).

Tem-se que a maiorias das técnicas existentes para monitorar o desgaste do dressador é baseada em métodos óticos. Habrat *et al.* (HABRAT, BATSCH e PORZYCKI, 2005), propôs um sistema de monitoramento ótico para a obtenção de um modelo do desgaste de dressadores. Contudo, esses métodos são muito sensíveis ao ambiente, principalmente ao fluído de corte, de modo que não são viáveis para um sistema de monitoramento em tempo real (EGAÑA, MENDIKUTE, *et al.*, 2006).

Essas limitações podem ser resolvidas obtendo-se características do processo através do processamento dos sinais relacionados à operação de dressagem. O sinal de emissão acústica tem-se mostrado de grande utilidade no monitoramento do desgaste do diamante,

sendo o sinal mais sensível às condições da operação de dressagem. O sinal de emissão acústica é um tipo de onda elástica ultrassônica que se propaga pelo material. Na operação de dressagem a energia desse sinal é proveniente do contato entre o rebolo e a ponta de diamante do dressador. Dessa forma todas as interações que ocorrem nesse contato podem ser usadas para caracterizar a condição da ferramenta (EGAÑA, MENDIKUTE, *et al.*, 2006).

Devido à alta complexidade das iterações decorrentes do processo não é possível determinar um modelo analítico para avaliar o desgaste do dressador. Nesse sentido, sistemas inteligentes ganham espaço na extração e extrapolação dos dados de testes realizados, fornecendo uma ferramenta eficiente para o monitoramento do processo (EGAÑA, MENDIKUTE, *et al.*, 2006).

Assim no presente trabalho foi realizado um estudo do desgaste de três tipos de diamantes para dressadores e, posteriormente, foram desenvolvidos modelos neurais capazes de classificar o nível de desgaste observado em um dado instante do ensaio.

1.2 OBJETIVO

Durante pesquisas sobre dressagem realizadas pelo grupo anteriores a este trabalho, se constatou uma ausência de métodos indiretos de monitoramento do desgaste de dressadores de ponta única. A partir dessa motivação foi desenvolvido o presente trabalho tendo como objetivos:

- Determinar uma metodologia para realização dos ensaios de desgaste do dressador.
- Formação de um banco de dados sobre o desgaste de dressadores, correlacionando a condição da ferramenta com um sinal de emissão acústica.
- Fornecer modelos neurais capazes de realizar a classificação do dressador em níveis de desgaste.

1.3 PUBLICAÇÕES RELACIONADAS

- MARTINS, C. H. R., AGUIAR, P. R., BIANCHI, C. E., RUZZI, R., FRECH, A. Application of MLP and Kohonen neural networks in the recognition of wear patterns of single-point dressers, 12th IASTED International Conference on Artificial Intelligence and Applications - AIA 2013, 2013, Innsbruck.

- AGUIAR, P. R., MARTINS, C. H. R., MARCHI, M., BIANCHI, E. C., Digital Signal Processing for Acoustic Emission, Data Acquisition Applications, Zdravko Karakehayov (editor), ISBN: 978-953-51-0713-2, InTech, DOI: 10.5772/48557, 2012.
- MARTINS, C. H. R., CHAVAGLIA, F., RUZZI, R., AGUIAR, P. R., BIANCHI, C. E. Processamento Digital de Sinais de Emissão Acústica na Estimção do Desgaste de Dressadores de Ponta Única. Congresso Nacional de Engenharia Mecânica - CONEM 2012, 2012, São Luís, CONEM2012-0855.
- MOIA, D. F. G., THOMAZZELLA, I. H., AGUIAR, P. R., BIANCHI, E. C., MARTINS, C. H. R. Redes Neurais Artificiais no Monitoramento da Operação de Dressagem. Congresso Nacional de Engenharia Mecânica - CONEM 2012, 2012, São Luís.
- NAKAI, M. E., MARTINS, C. H. R., LUZIA, R. F., MARCHI, M., AGUIAR, P. R., BIANCHI, C. E. Monitoramento da Operação de Dressagem Baseado em Controlador Digital de Sinais, X Conferência Brasileira de Dinâmica, Controle e Aplicações (DINCON 2011), 2011, Águas de Lindóia, SP.

CAPITULO 2 - REVISÃO BIBLIOGRÁFICA

2.1 O PROCESSO DE RETIFICAÇÃO

Dentre os processos de usinagem, nome genérico dado ao processo de remoção de material, está o processo de retificação (SALMON, 1992). Este consiste na utilização de um rebolo formado por grãos abrasivos rotacionado a uma alta velocidade de corte para a remoção de material (MARINESCU, HITCHINER, *et al.*, 2007). Diferente de outros processos, tais como torneamento e fresamento, a retificação se utiliza de uma ferramenta de corte não definida; isso se deve ao fato dos grãos abrasivos não apresentarem arestas de corte regulares. Dessa forma, vários fatores podem afetar o resultado do processo (KWAK e HA, 2004) (REN, ZHANG e ZHOU, 2009).

Dessa forma, o processo de retificação é um dos mais complexos dentre os processos utilizados na usinagem (LIAO, TING, *et al.*, 2007). Por ser utilizado no acabamento de peças a fim de se obter produtos e superfícies avançadas, normalmente corresponde a uma etapa final da usinagem na linha de produção, não sendo, portanto, toleradas falhas nesse processo. Para garantir os resultados da retificação é necessário uma alta capacitação do operador e um extenso estudo sobre a dinâmica do processo (MALKIN, 2008) (DURGUMAHANTI, VIJAYENDER e VENKATESWARA, 2010).

A Figura 1 apresenta as quatro operações básicas da retificação: a retificação tangencial plana e cilíndrica, e a retificação lateral plana e cilíndrica. As operações de retificação são classificadas de acordo com a superfície do rebolo em contato com a peça e com o avanço do rebolo. De acordo com a forma geométrica das superfícies obtidas são divididas em cilíndrica externa, cilíndrica interna, plana e plana rotativa. Conforme o movimento de avanço são divididas em tangencial de mergulho, tangencial de passagem, lateral (ou de face) de mergulho e lateral de passagem. Na prática, a gama de possibilidades de processos de retificação é grande e inclui uma variedade de operações de geração de perfil, cópia de perfil, corte e ranhuras (MARINESCU, HITCHINER, *et al.*, 2007) (SCHÜHLI, 2007). Neste trabalho será dada ênfase ao processo de retificação tangencial plana.




Figura 1 - Operações básicas na retificação, adaptado (MARINESCU, HITCHINER, *et al.*, 2007).

2.1.1 PARÂMETROS NA RETIFICAÇÃO PLANA

A interação rebolo-peça no processo de retificação, tipicamente possui os seguintes parâmetros de entrada: taxa de remoção, velocidade de corte do rebolo e da peça, agressividade e tempo de centelhamento (spark-out) (KING & HAHN, 1992). A agressividade do rebolo também é uma importante variável do processo (HELLMEISTER, 2004).

2.1.1.1 Profundidade de corte (a)

Pode ser definida como a penetração do rebolo na peça que está sendo retificada. É medida como sendo a espessura equivalente de material removido por passagem do rebolo na peça (MARINESCU, HITCHINER, *et al.*, 2007). Corresponde a grandeza - a [μm] - que é tomada perpendicularmente à direção de avanço da peça ou do rebolo (DINIZ, MARCONDES e COPPINI, 2003).

Para valores elevados da profundidade de corte ocorre um aumento das forças de corte, as quais são responsáveis pelas deformações causadas entre o rebolo e a peça (KÖNIG e KLOCKE, 1980). Esse parâmetro também deve exercer influência no acabamento superficial dos componentes retificados (LINKE, 2008).

2.1.1.2 Velocidade de corte (V_s)

O deslocamento de um ponto sobre a superfície de corte do rebolo, por exemplo, um grão, por uma variação de tempo determina a sua velocidade de corte, ou velocidade periférica do rebolo. A partir dessa velocidade pode-se determinar a vida do rebolo, já que ela implica diretamente na alteração da capacidade de remoção dos grãos abrasivos e no acabamento das peças (MALKIN, 2008).

A velocidade de corte pode ser expressa pela equação (GRAF, 2004):

$$V_s = \frac{\pi \cdot d_s \cdot n_s}{60 \cdot 1000} \text{ [m/s]} \quad (1)$$

onde:

- d_s [mm] é o diâmetro externo do rebolo;
- n_s [rpm] a rotação do rebolo.

2.1.1.3 Velocidade da peça (V_w)

Na retificação plana, a velocidade da peça assemelha-se a velocidade da mesa, sendo normalmente expressa em metros por minuto (MARINESCU, HITCHINER, *et al.*, 2007).

Com o aumento da velocidade da peça ocorre uma elevação na taxa de remoção de material, com isso geram-se cavacos com alta espessura e conseqüentemente aumenta a força sobre cada grão do rebolo. Com isso os valores de força tangencial de corte são elevados (GRAF, 2004).

2.1.1.4 Comprimento de contato (l_c)

Pode ser definido com a extensão de contato entre a peça e o rebolo (MARINESCU, ROWE, *et al.*, 2004), como ilustrado na Figura 2.




Figura 2 - Esquema dos parâmetros: velocidade do rebolo V_s ; velocidade da peça V_w ; profundidade de corte a ; comprimento de contato l_c . Adaptado (MALKIN, 1989).

De acordo com Malkin, o comprimento de contato pode ser definido pela equação $l_c = (a \cdot d_s)^{\frac{1}{2}} [\mu m]$ (2). Porém esta equação não considera os movimentos e possíveis deformações decorrentes do contato rebolo-peça, dessa forma ela descreve apenas uma suposta área de contato (MALKIN, 2008).

$$l_c = (a \cdot d_s)^{\frac{1}{2}} [\mu m] \quad (2)$$

Onde:

- a [μm] é a profundidade de corte;
- d_s [mm] é o diâmetro externo do rebolo.

2.1.1.5 Taxa de remoção de material (Q_w)

É uma grandeza que relaciona profundidade de corte (a), velocidade relativa entre a peça e o rebolo (v_w) e a largura de retificação (b), sendo a equação dada por (MALKIN, 2008).

$$Q_w = a \cdot v_w \cdot b \quad (3)$$

Ainda segundo Malkin (MALKIN, 2008), existe a taxa específica de remoção (Q'_w), que corresponde à taxa de remoção de material dividida pela largura de retificação:

$$Q'_w = a \cdot v_w [mm/s] \quad (4)$$

2.1.1.6 Espessura equivalente de corte (h_{eq})

A espessura equivalente de corte é a espessura de material removido pelo rebolo com a velocidade de corte deste. Corresponde à razão entre a taxa específica de remoção de material (Q'_w) e a velocidade de corte (v_s):

$$h_{eq} = \frac{Q'_w}{v_s} = \frac{a \cdot v_w}{v_s} \quad (5)$$

2.1.2 FORÇAS DE CORTE NO PROCESSO DE RETIFICAÇÃO

Os esforços de corte no processo de retificação são gerados entre a interação do abrasivo e a peça em forma de deformação plástica e elástica, pela formação do cavaco e pelo atrito entre abrasivo, ligante e peça (REN, ZHANG e ZHOU, 2009).

Geralmente essa força é decomposta em três componentes: normal (F_n) [N]; tangencial (F_t) [N]; e uma componente ao longo da direção de avanço longitudinal (axial - F_a) [N], que não possui muita significância. A força tangencial afeta principalmente o consumo de energia e o tempo de vida de serviço do rebolo, assim afeta também na temperatura e rugosidade da peça usinada (LI, 2002). A Figura 3 apresenta um esquema dessas forças na retificação plana.




Figura 3 - Componentes de força para retificação tangencial plana, adaptado (MALKIN, 1989).

A força normal atua perpendicularmente à superfície do rebolo e depende da dureza do grão abrasivo e do material a ser usinado. Esta é maior que a tangencial e age diretamente na redução da profundidade de corte, sendo também responsável por deflexões da peça, rebolo e estrutura da máquina. A componente axial só ganhará importância quando houver certo deslocamento lateral do rebolo (MARINESCU, ROWE, *et al.*, 2004).

A força tangencial de corte em um grão abrasivo é expressa pela equação:

$$F_t = b \cdot h_{max} \cdot K_S + \mu \cdot b^2 \cdot \pi \cdot \frac{K_n}{4} \text{ [N]} \quad (6)$$

Onde:

- b [mm] largura média no topo dos grãos abrasivos;
- K_S [N/mm²] pressão específica de corte;

- μ coeficiente de atrito entre grão e peça;
- K_n [N/mm²] tensão de escoamento do material.

2.1.3 POTÊNCIA NA RETIFICAÇÃO

A potência de retificação é associada à velocidade de corte (V_S) e a velocidade da peça (V_W), segundo a Equação (6) (MALKIN, 2008). A força tangencial (F_t) é a componente da força de retificação responsável pela dissipação de potência em situações de alta velocidade do rebolo (MARINESCU, ROWE, *et al.*, 2004).

$$P = F_t \cdot (V_S \pm V_W) [W] \quad (7)$$

O sinal positivo indica que V_S e V_W têm direções opostas e o sinal negativo indica mesma direção.

2.1.4 RUGOSIDADE DAS PEÇAS RETIFICADAS

A retificação é um processo principalmente utilizado para acabamento, e a rugosidade é um dos fatores mais importantes para mensurar a qualidade superficial de um componente. No entanto, não há um modelo de compreensão do comportamento dessa variável em uma operação de retificação. A dificuldade em se prever tal parâmetro vem do fato deste ser influenciado por inúmeras variáveis do processo, como as propriedades do material da peça, as características dos constituintes do rebolo, as condições de dressagem, os parâmetros de corte, a forma de aplicação e o tipo de fluido de corte, vibrações da máquina, e outros tantos fatores (MALKIN, 2008).

Um método eficiente de se mensurar a qualidade da superfície produzida é por meio da rugosidade. Esta pode ser definida como micro irregularidades geométrica decorrentes do processo de fabricação. A medição é feita em função da distância entre picos e vales existentes na superfície produzida. Assim, podem-se destacar os principais parâmetros utilizados atualmente para obter a rugosidade: pela média dos valores dessa distância (parâmetro Ra), pelo valor quadrático médio dessa distância (parâmetro Rq) ou ainda pelo valor máximo da mesma (parâmetro Rt) (HECKER, LIANG e WU, 2003).

2.2 REBOLO

O rebolo é a ferramenta de revolução utilizada nos processos de retificação. O corpo abrasivo do rebolo é composto por grãos abrasivos unidos por um ligante. Esses grãos são responsáveis pela remoção de material através de suas arestas de corte de geometria indefinida. Pode-se considerar o rebolo como um sistema trifásico, sendo constituído por grãos abrasivos, aglomerante e poros. Desse modo, seu desempenho está relacionado ao tipo e tamanho do grão abrasivo, as propriedades abrasivas do material e porosidade do conjunto (MALKIN, 2008).

As principais características que definem o tipo de um rebolo são: tipo do abrasivo; ligante; dureza; granulometria e estrutura (STEMMER, 1992). Nesse trabalho foram utilizados rebolos convencionais de óxido de alumínio com ligante vitrificado, dureza média e granulometria muito fina.

2.2.1 GRÃOS ABRASIVOS

Os grãos abrasivos usados nas operações de retificação são partículas refratárias duras e frágeis que podem ser classificadas de acordo com sua dureza ou composição química (LIAO, TING, *et al.*, 2007).

A propriedade mais importante de um abrasivo é que este seja mais duro que o material a ser retificado. Casualmente define-se essa dureza em termos resistência e endentação estática, obtidos através de um teste de dureza Knoop (MALKIN, 2008).

A avaliação e escolha de certo abrasivo tomam por base a sua friabilidade. Essa característica pode ser definida como, a tendência da desintegração do grão em pequenos fragmentos quando sob pressão. Essa tendência deve-se a forma, a integridade e a pureza do cristal que forma o grão abrasivo (MARINESCU, ROWE, *et al.*, 2004).

Os grãos abrasivos podem ser classificados em dois grupos distintos, os grãos naturais e os grãos artificiais, pode-se ainda subdividir estes em mais dois grupos, os abrasivos convencionais e os superabrasivos (SALMON, 1992).

2.2.2 LIGANTES

Os ligantes são responsáveis por unir os grãos abrasivos em uma ferramenta abrasiva (SALMON, 1992). Tendo como principais funções: reter o grão durante o processo de

usinagem; desgastar-se numa taxa controlada; resistir à força centrífuga em altas velocidades; e a de rapidamente expor o grão ao trabalho (WEBSTER, 2007).

Os principais ligantes utilizados são os resinoides, os vitrificados e os metálicos. O uso correto do ligante durante a fabricação dos rebolos tem como objetivo tornar a distribuição dos grãos sobre o rebolo o mais uniforme possível, prejudicando da menor forma possível o processo de retificação (HEINZEL e RICKENS, 2009).

2.2.3 DUREZA

A dureza de um rebolo está relacionada com a força com que o ligante retém o grão abrasivo na sua posição sob as forças de retificação. É determinada pela quantidade de ligante misturado com os grãos abrasivos (SALMON, 1992).

Esta dureza é diretamente dependente das propriedades mecânicas do ligante, pois se este possuir uma resistência mecânica elevada, a possibilidade de ruptura dos grãos abrasivos será reduzida, isto devido a uma acomodação dos impactos sofridos pelo rebolo. Além disso, uma resistência elevada ao desgaste do material ligante dificulta a remoção de grãos inteiros, já que a ancoragem dos grãos se mantém estável durante toda a vida do rebolo (KING e HAHN, 1992).

2.2.4 GRANULOMETRIA

Para rebolos convencionais, o tamanho do grão abrasivo é classificado através do método de peneiramento, sendo designado pelo número que corresponde à divisão linear da área de uma polegada quadrada. Assim, quanto mais fino o grão, maior será o seu número na escala da granulometria (MALKIN, 2008).

O tamanho do grão influencia a taxa de remoção e o acabamento obtido na retificação. Os grãos classificados como grossos são usados comumente para operações grosseiras. Sendo aplicados geralmente na usinagem de materiais moles, dúcteis ou fibrosos (DINIZ, MARCONDES e COPPINI, 2010). A utilização de grãos mais grossos permite uma maior taxa de remoção de material enquanto que grãos mais finos produz um acabamento melhor (MALKIN, 2008).

2.2.5 ESTRUTURA

Uma propriedade adicional aos rebolos é sua estrutura: densidade de grãos e porosidade. Caso seja feita uma mistura de grãos muito finos com uma quantidade grande de ligante sob elevada pressão, resulta em baixa porosidade. Entretanto, se for utilizado grãos grossos, o resultado será uma estrutura mais aberta e, conseqüentemente, mais porosa. Para induzir a porosidade no rebolo, podem ser usados elementos voláteis durante o estágio verde, antes do forno (SALMON, 1992).

A porosidade pode ser descrita como a medida de espaçamento entre os grãos abrasivos. Corresponde a um efeito local na estrutura do rebolo que faz com que haja fluxo de fluido e acomodação do cavaco (WEBSTER, 2007).

2.3 A OPERAÇÃO DE DRESSAGEM

Idealmente, as partículas abrasivas da superfície de corte do rebolo deveriam ser afiadas automaticamente conforme o rebolo é desgastado, já que, a partir do desprendimento integral ou fratura dessas partículas abrasivas, há exposição de novas partículas com arestas de corte afiadas. Contudo, na prática tanto a geometria como as características funcionais do rebolo devem ser restauradas periodicamente através da operação de dressagem. Dressagem consiste em uma operação de afiamento concebida para gerar uma topografia particular na superfície de corte do rebolo (JACKSON, KHANGAR, *et al.*, 2007).

Entender a operação de dressagem é um fator crítico para a obtenção de ótimo processo de retificação (MARINESCU, HITCHINER, *et al.*, 2007). Inicialmente a topografia e forma macroscópica do rebolo são geradas pela preparação do mesmo por meio da dressagem (MALKIN, 2008).

A dressagem - do inglês *dressing* - é o processo conjunto entre perfilar e afiar o rebolo. No afiamento do rebolo ocorre a remoção do ligante entre os grãos abrasivos. Assim, a dressagem tem como objetivo restaurar a eficiência de corte da ferramenta (MARINESCU, HITCHINER, *et al.*, 2007).

2.3.1 DRESSAGEM E TOPOGRAFIA

Segundo (LIN, LIU e HUANG, 2008) a topografia do rebolo é caracterizada pelo número de arestas de corte. De modo que, essa topografia tem influência sobre a geometria do

cavaco produzido e no processo de retificação como um todo. Pode-se então considerar que o processo de retificação engloba tanto a dressagem como a própria retificação. Do ponto de vista de remoção do material, as propriedades estáticas mais importantes da topografia do rebolo são os parâmetros relacionados à aresta de corte e sua distribuição. Tais parâmetros são a afiação, a largura e densidade de arestas. Sendo a largura e a densidade, relacionadas ao número de arestas de corte ativas por unidade de área da superfície de corte do rebolo. O número de arestas ativas depende das condições impostas de dressagem. E a superfície de corte do rebolo é gerada pela fratura do grão ou do ligante (SALEH, BISHWAS e RAHMAN, 2009).

2.3.2 DRESSADOR DE PONTA ÚNICA

O dressador de ponta única é a ferramenta de dressagem mais simples, sendo largamente utilizado nas operações de dressagem (SALMON, 1992), (MARINESCU, HITCHINER, *et al.*, 2007). A operação de dressagem realizada com um dressador de ponta única também é conhecida por dressagem mecânica (HARIMKAR, SAMANT, *et al.*, 2006).

O dressador de ponta única carrega um único diamante, que deve formar um ângulo de ataque limpo em relação ao rebolo para que o processo de dressagem seja eficiente. Se o diamante estiver perpendicular ao rebolo durante a dressagem, ele será gasto rapidamente. Se o ângulo do diamante for igual ao da superfície do rebolo a região de contato irá gerar muito calor, podendo danificar o diamante (SALMON, 1992). O dressador de ponta única é usualmente instalado com um ângulo relativo entre a ferramenta e o rebolo de α_d entre 10° e 15° (MALKIN, 2008).

Segundo (MALKIN, 2008), a operação de dressagem de ponta única produz dois efeitos na superfície do rebolo o macro e micro efeito, que são definidos como:

- Macro efeito: gerado a partir do formato do dressador, da profundidade de penetração do dressador e do passo de dressagem. Este fenômeno determina a posição das novas arestas dos grãos abrasivos na superfície do rebolo.
- Micro efeito: gerado pelo arrancamento dos grãos gastos, isso é com baixa ancoragem ao ligante, e pela fratura dos grãos que não se desgastaram por completo, onde novas arestas de corte são geradas.

Na operação de dressagem de rebolos convencionais, é usual que o dressador passe pelo rebolo rotacionado, como ilustrado na Figura 4. Durante cada passada do dressador através do rebolo, é removida uma profundidade a_d do raio do rebolo. Esse tipo de

movimento de dressagem é análogo ao de torneamento. O avanço axial do dressador por revolução é chamado de direção de dressagem, s_d , e é dado e pela Equação (8).

$$S_d = \frac{\pi \cdot d_s \cdot v_d}{v_s} \quad (8)$$

Onde:

- v_d [mm/s] é a velocidade de dressagem;
- v_s [mm/s] é a velocidade de corte do rebolo;
- d_s [mm] é o diâmetro do rebolo.




Figura 4 - Representação esquemática do processo de dressagem, adaptado (OLIVEIRA e BIANCHI, 1992).

2.3.2.1 Grau de recobrimento de dressagem (U_d)

O grau de recobrimento de dressagem (U_d) é um parâmetro de dressagem importantíssimo que foi criado por (KÖNIG e KLOCKE, 1980) e que tem como objetivo relacionar os parâmetros de dressagem e a topografia do rebolo gerada na operação. A definição do grau de recobrimento na dressagem com dressador de ponta única é a de determinar quantas vezes um ponto da superfície do rebolo é recoberto pela largura útil do dressador (b_d [mm]) pelo avanço (s_d [mm]) de dressagem (MALKIN, 2008).

Quanto menor for o grau de recobrimento, não ultrapassando o valor mínimo de um, maior será a agressividade do rebolo. Uma alta agressividade no rebolo prejudica a qualidade superficial das peças retificadas, porém favorece a remoção de grandes quantidades de material. No contrário, quanto maior o grau de recobrimento, menor é a agressividade do rebolo (KÖNIG e KLOCKE, 1980).

2.4 DIAMANTES PARA DRESSADORES

Além do aspecto estético do diamante em forma de pedras preciosas, ele é o material mais duro conhecido, de tal modo que está no topo da escala de Mohs. Devido a essa propriedade, os diamantes são usados em diversas aplicações tecnológicas tais como abrasão, corte e polimento. Dentre os materiais o diamante é aquele que apresenta a maior condutividade térmica a temperatura ambiente, sendo quatro vezes superior a do cobre ou da prata, é um bom isolante elétrico, possui uma constante dielétrica pequena (KOIZUMI, KAMO, *et al.*, 1997).

Ainda segundo Koizumi *et al.* (KOIZUMI, KAMO, *et al.*, 1997), os diamantes possuem um coeficiente de desgaste e de expansão térmica pequeno, elevada resistência química e de corrosão para a maioria dos ácidos e substâncias oxidantes, e é opticamente transparente.

Os monocristais de diamantes com alto índice de pureza são usados como pedras preciosas para joias. Industrialmente, são utilizados para triturar ou cortar outros materiais. A grande desvantagem do diamante natural para o uso industrial é o seu elevado custo (CALLISTER, 2002).

2.4.1 DIAMANTES SINTÉTICOS - CVD

O grande interesse pela síntese de diamante é de replicar as propriedades físico-químicas do diamante natural, de modo que o diamante sintético apresente elevada dureza, baixa densidade, baixo coeficiente de expansão térmica, alto índice de refração, alta condutividade térmica à temperatura ambiente, excelente isolante elétrica, inerte quimicamente, apresenta compatibilidade biológica e quando dopado torna-se um bom semicondutor (ANGUS, 1995).

A técnica de fabricação de diamantes sintéticos em altas pressões já era dominada nas décadas de 50 e 60, essas pressões eram superiores a 60.000 atm e temperaturas acima de

2000 K. As principais aplicações para esses diamantes sintéticos eram em ferramentas de corte e para polimento de superfícies. A partir da década de 70 começaram a surgir trabalhos acadêmicos que buscavam obter pequenas camadas de diamante através de gases compostos por carbono (BROOKES, 2010).

Essas camadas, denominadas filmes, eram produzidas em pressões inferiores a uma atmosfera e em temperaturas abaixo de 1200 K, em substratos incrustados com pó de diamante. A partir disso, a técnica de obtenção de diamante a partir de um gás precursor se disseminou pelo mundo, como um método mais fácil e produtivo do que aquele utilizado nas décadas de 50 e 60. Os diamantes sintéticos criados por esta técnica passaram a se chamar de diamante CVD (ANGUS e HAYMAN, 1988).

Contudo, as propriedades mecânicas, elétricas e óticas das películas dos diamantes CVD se aproximam daquelas do diamante natural, mas ainda não de forma satisfatória (CALLISTER, 2002).

2.5 MONITORAMENTO DO PROCESSO DE RETIFICAÇÃO

O desenvolvimento de um sistema de monitoração e controle em tempo real é de fundamental importância para se obter automação dos processos de usinagem. De modo que se tenha um processo capaz de estabelecer o momento da troca de uma ferramenta, realizar a troca e realizar mudanças nos parâmetros de operação visando a otimização do processo (AGUIAR, SOUZA, *et al.*, 2009).

A tecnologia de emissão acústica (EA) tem avançado significativamente sendo amplamente investigada como um método não destrutivo para o monitoramento de processos de usinagem. A emissão acústica é definida como a liberação de ondas oscilatórias emitidas por um material reagindo a um esforço. As emissões acústicas geradas durante os processos de usinagem são relacionadas com o estado do processo e condições da ferramenta e peça (WANG, WANG, *et al.*, 2005).

Através de uma série de experimentos (XUE e NAGHDY, 2002) confirmou que a emissão acústica é um mecanismo eficiente no monitoramento da dressagem tanto quanto para o processo de retificação. Embora haja vários estudos sobre dressagem e sua influência nas variáveis de saída do processo de retificação, a maioria dos trabalhos analisa este ponto de forma qualitativa.

O processo de dressagem pode ser monitorado para produzir uma qualidade constante na superfície do rebolo. A partir do monitoramento das amplitudes e frequências

características do sinal de EA é possível definir a vida do rebolo (INASAKI e OKAMURA, 1985).

Segundo (XUE e NAGHDY, 2002) a ponta do dressador é um fator que afeta significativamente a rugosidade da peça quando comparado com outros parâmetros do processo de retificação, tais como profundidade de corte e velocidade da mesa. O monitoramento dos parâmetros de dressagem resulta em valores mais consistentes de rugosidade para a operação de retificação.

Erros de dressagem podem afetar diferentemente a qualidade da dressagem devido a flutuações da profundidade real de dressagem, desgaste do dressador e outros distúrbios. Um sistema de monitoramento pode detectar essas condições indesejáveis (XUE e NAGHDY, 2002).

2.6 EMISSÃO ACÚSTICA

Emissão acústica é a propagação de uma onda elástica na rede dos materiais cristalinos devido ao rearranjo da estrutura interna do material. Quando ocorre uma deformação no material (modificado por corte, atrito, trinca entre outros) acontece um desarranjo da estrutura do material que tende a se reestruturar. Nesse momento são geradas ondas vibracionais que se deslocam a velocidade do som, daí o nome de emissão acústica. Estes sinais são captados por meio de um sensor que transforma os sinais mecânicos em sinais elétricos (WILLIAMS, 1968).

Uma grande variedade de sensores de emissão acústica, especialmente os produzidos para o propósito de monitoramento, tem sido aplicados na indústria. Eles reúnem características importantes tais como: baixo custo, fácil montagem, resistência à influência externas, e são capazes de monitorar peças em rotação (MARINESCU, HITCHINER, *et al.*, 2007).

2.7 PROCESSAMENTO DE SINAIS

O processamento de um sinal consiste em se aplicar transformações a um sinal analógico, ou digital, com o objetivo de eliminar ruídos e extrair características do sinal. Algumas operações comumente utilizadas no processamento de sinais são: ampliação, filtragem, transformações matemáticas, integração de sinais, conversão analógico para digital.

Pesquisadores como (INASAKI, KARPUSCHEWSKI e WEHMEIRER, 2000), (INASAKI e OKAMURA, 1985), (KWAK e HA, 2004), (LEE, HWANG, *et al.*, 2006) entre outros, utilizaram técnicas de aquisição de dados e processamento de sinais em estudos relacionados ao monitoramento do processo de retificação.

2.7.1 VALOR EFICAZ DE UM SINAL (RMS)

O valor médio quadrático (do inglês, *Root Mean Square*) de um sinal puro S pode ser expresso pelas Equações (9) e (10) para um sinal contínuo e para um sinal discreto, respectivamente (NILSSON e RIEDEL, 2003).

$$S_{RMS} = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} S^2(t) \cdot dt} \quad (9)$$

$$S_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N S^2(i)} \quad (10)$$

Onde:

- T é o intervalo de tempo para o cálculo do valor RMS;
- t_0 o ponto de início da análise no tempo;
- N é o número discreto de dados do sinal S no intervalo de tempo T ;
- S é o sinal puro;
- S_{RMS} é o valor RMS.

2.7.2 TAXA DE POTÊNCIA DE UM SINAL (ROP)

A taxa de potência de um sinal (do inglês, *ratio of power*) observa o sinal quanto ao seu espectro de frequência. Para cada bloco de sinal de EA o valor ROP é dado pela equação (11).

$$ROP = \frac{\sum_{k=n_1}^{n_2} |X_k|^2}{\sum_{k=0}^{N-1} |X_k|^2} \quad (11)$$

Onde:

- N é o tamanho do bloco de sinal de EA;

- n_1 e n_2 definem uma faixa de frequência para análise.

2.7.3 TRANSFORMADA DISCRETA DE FOURIER (DFT)

Uma das ferramentas mais poderosas encontrada na área de processamento digital de sinais é a transformada de discreta de Fourier. É um procedimento matemático usado para determinar o conteúdo harmônico ou de frequência de um sinal discreto no tempo. A DFT é calculada de acordo com a equação (12).

$$X(m) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi nm/N} \quad (12)$$

Onde:

- X é o valor da DFT;
- m é o índice da componente de saída da DFT no domínio da frequência;
- x a sequência de amostras do sinal discreto;
- n é o índice no domínio do tempo das amostras, $n = 0, 1, 2, 3, \dots, N-1$;
- $j = \sqrt{-1}$;
- N é o número de amostras.

Embora a DFT seja um dos procedimentos matemáticos mais diretos para determinar o conteúdo de frequência de um sinal discreto, ela é ineficaz devido à lentidão do processo. Uma forma eficiente de se calcular o conteúdo harmônico do sinal é utilizar a transformada rápida de Fourier (FFT) (YANG e CHEN, 2002).

2.7.4 MÉDIA E DESVIO PADRÃO

A média e o desvio padrão são comumente empregados para a determinação do valor médio e da dispersão de um sinal, respectivamente. Estas estatísticas descrevem a amplitude da distribuição, a simetria e a sua forma. A média é calculada a partir da Equação (13).

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (13)$$

Onde:

- x_i é o valor i da amostra;

- \bar{x} é a média dos valores no intervalo n ;
- n é o tamanho da amostras.

O desvio padrão normalmente é usado para indicar a variação em um conjunto de amostras. O desvio padrão de uma população de valores é definido pela Equação (14) (MORETTIN, 1999).

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (14)$$

Onde:

- \bar{x} é o valor médio da amostra;
- x_i é o valor i da amostra;
- n é o tamanho da amostra;
- σ é o desvio padrão.

2.8 REDES NEURAIS ARTIFICIAIS (RNA)

As redes neurais artificiais (RNAs) são uma maneira de criar modelos matemáticos, com capacidade de processar informações, inspirados em uma estrutura natural: o cérebro humano. Estes modelos foram inspirados em algumas operações conhecidas do cérebro humano, ou seja, apresentam capacidade de aprender, de tomar decisões, e de adaptar-se mesmo em presença de sinais ruidosos (HARTMANN, 2002). As características garantem a RNA à capacidade de aprender através de exemplos e então generalizar os padrões do conjunto de dados de treinamento, tornando possível a interpretação de outros padrões similares, mas não idênticos, aos utilizados durante o aprendizado.

Uma rede neural é definida por Kohonen como uma rede interconectada paralelamente de elementos simples e sua organizações hierárquicas tem como objetivo interagir com o mundo real (KOHONEN, 1988).

Os componentes básicos da RNA são os neurônios e seus pesos. Estes pesos são ajustáveis e correspondem a sinapses biológicas. Um peso positivo representa uma excitação e o peso negativo uma inibição. As entradas do neurônio são então pesadas por uma função de ativação que determina o valor de saída (HUANG, 1994).

Na Figura 5 é apresentado um neurônio biológico, esse neurônio recebe os estímulos (sinapse) nas suas conexões de entrada (dendritos), se as condições necessárias são satisfeitas,

um sinal é emitido na saída (axônio) (NEGNEVITSKY, 2005). Na representam matemática do neurônio, o neurônio artificial, as entradas recebidas são multiplicadas por pesos sinápticos, que correspondem à força de determinada entrada para a emissão da saída e uma soma ponderada é calculada. O resultado dessa soma é comparado a um limite de ativação do neurônio (HAYKIN, 1999). A Figura 6 mostra o modelo do neurônio artificial.




Figura 5 - Modelo de neurônio biológico, adaptado (NEGNEVITSKY, 2005).

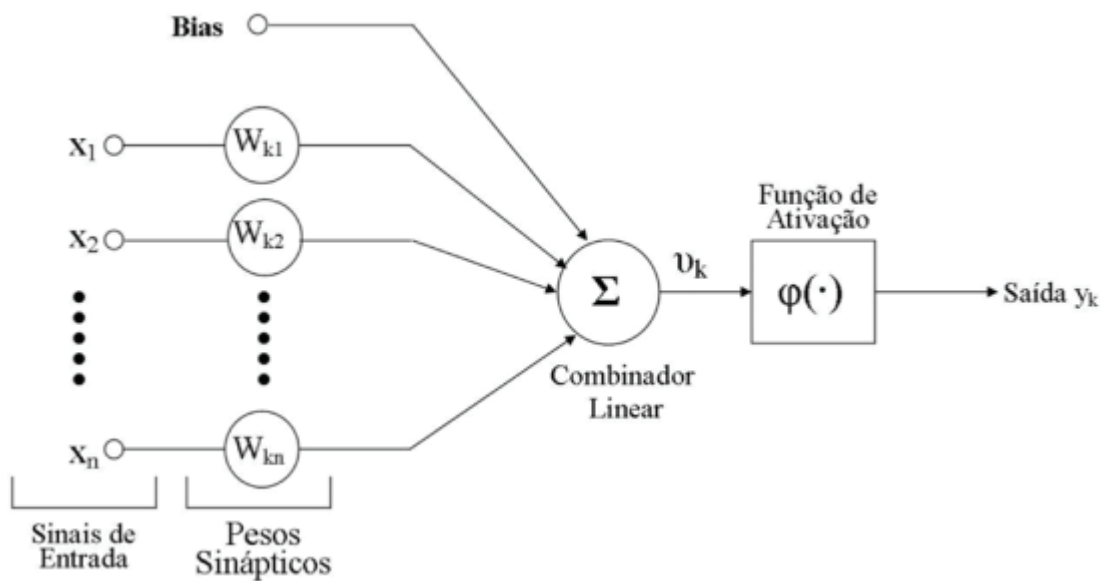


Figura 6 - Modelo do neurônio artificial (HAYKIN, 1999).

Um neurônio artificial k pode ser descrito pelas Equações (14) e (15) (HAYKIN, 1999).

$$V_k = \sum_{i=1}^n w_{ki} \cdot x_i \quad (15)$$

$$y_k = \varphi(V_k + b_k) \quad (16)$$

Onde:

- n é o número de entradas;
- x_1, x_2, \dots, x_n são os sinais de entrada;
- w_1, w_2, \dots, w_n são os pesos sinápticos;
- V_k é a saída do combinador linear;
- b_k é o limiar de ativação e tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação;
- φ é a função de ativação, responsável por buscar um ajuste ótimo;
- y_k é a saída do neurônio.

2.8.1 REDE NEURAL *PERCEPTRON* DE MÚLTIPLAS CAMADAS

Atualmente, a rede *perceptron* de múltiplas camadas (MLP), tem sido a arquitetura de RNA mais usada, sendo amplamente apresentada na maioria das literaturas sobre redes neurais. Redes MLP são redes alimentadas adiante (*feedforward*) que possuem uma ou mais camadas de neurônios entre as camadas de entrada e saída, estas camadas são denominadas de camada oculta. Esta camada oculta adiciona um poder maior a rede em relação às redes *perceptron* de camada única, que classifica apenas padrões linearmente separáveis, sendo os neurônios ocultos os responsáveis por capturar a não linearidade dos dados. Na rede MLP os neurônios são conectados aos neurônios da camada subsequente, não havendo ligação entre os neurônios da mesma camada e também não ocorre realimentação (HAYKIN, 1999).

O processo de aprendizagem da rede neural MLP é iterativo, conhecido como aprendizagem por experiência, cujos padrões de treinamento são apresentados a rede, e com base nos erros obtidos são realizados ajustes nos pesos sinápticos com o intuito de diminuir este erro para as próximas iterações. O algoritmo de treinamento comumente empregado é o de retropropagação de erro (*error backpropagation*), baseado na regra de aprendizagem por correção de erro, que consiste em dois passos. O primeiro passo, para frente, é chamado de propagação, os valores provindos dos neurônios de entrada são aplicados aos neurônios ocultos, e posteriormente, suas saídas são aplicadas como entradas aos neurônios da camada de saída, obtendo a resposta da rede. No segundo passo, para trás, ocorre o ajuste dos pesos sinápticos, por meio do cálculo do erro obtido na camada de saída. O ajuste dos pesos é realizado de acordo com uma regra de correção (HAYKIN, 1999), (DYMINSKI, 2000). A Figura 7 apresenta um modelo genérico de uma rede MLP.




Figura 7 - Exemplo de uma rede MLP (DYMINSKI, 2000).

Uma das dificuldades do uso de RNAs consiste em identificar o melhor ponto de parada do treinamento, pois o erro de treinamento inicia com um valor alto, decresce rapidamente, e continua diminuindo mais lentamente, tendendo a atingir um mínimo local na superfície de erro. Assim, para se identificar o momento ideal de parar o processo de aprendizado, buscando obter a melhor generalização possível, é indicado utilizar a técnica da regra de parada antecipada, com base na validação cruzada. Esta técnica consiste em se validar o modelo obtido durante o treinamento, utilizando-se de um conjunto de dados diferentes dos usados no processo de aprendizado da rede (HAYKIN, 1999).

2.8.1.1 Função de treinamento Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt foi criado como um método de otimização que consiste em uma técnica iterativa de busca ao mínimo de uma função multivariada expressa como a soma de quadrados de funções não lineares (LEVENBERG, 1944) (MARQUARDT, 1963).

Como comumente nas redes neurais a função erro corresponde a uma soma de quadrados, este algoritmo foi desenvolvido com o objetivo de se acelerar o treinamento da rede neural utilizando métodos de segunda ordem sem o cálculo da matriz Hessiana. Para esse caso a matriz Hessiana pode ser aproximada pela Equação $H = J^T \cdot J$ (17) e o gradiente pela Equação $g = J^T$ (18). Sendo que, J é a matriz Jacobiana contendo as derivadas dos erros da rede em relação ao peso, e o vetor e corresponde aos erros da rede neural. A aproximação da matriz Hessiana é utilizada pelo algoritmo de Levenberg-Marquardt para atualização dos pesos, w , conforma a Equação $w_{i+1} = w^i - (J^T J + \mu I)^{-1} J^T e$ (19) (MUÑOZ, 2009).

$$H = J^T \cdot J \quad (17)$$

$$g = J^T \quad (18)$$

$$w^{i+1} = w^i - (J^T J + \mu I)^{-1} J^T e \quad (19)$$

O escalar μ é variável, sendo ajustado de modo a localizar o menor erro da forma mais eficiente possível. De modo que, μ cresce com a diminuição da função custo, resultando em passos menores na atualização dos pesos, e analogamente decresce com o aumento da função custo, que resulta em passos mais largos. Assim, quanto mais distante se estiver do ponto mínimo, maior será o passo na direção do gradiente, já quando se aproximar dele irá predominar o método de Newton (MUÑOZ, 2009) (MUKHERJEE e ROUTROY, 2012).

2.8.2 REDE NEURAL DE KOHONEN

A rede neural de Kohonen, conhecida também por mapa auto-organizável, define uma rede neural de duas camadas que implementam uma projeção não linear de um espaço multi dimensional, proveniente dos sinais de sensoriamento ou outros sinais de entrada, em um espaço de menor dimensão, formado pelos neurônios da rede (YANG, HAN e AN, 2004). Em outras palavras, os mapas auto-organizáveis facilitam a obtenção automática de mapas topológicos das características do evento observado (KOHONEN, 1982). Dessa forma, o principal objetivo da rede neural de Kohonen é transformar os padrões de entrada de dimensão arbitrária em um mapa discreto, onde cada célula desse mapa corresponde a um neurônio (HAYKIN, 1999). A estrutura geral de uma rede neural de Kohonen é ilustrada na Figura 8.




Figura 8 - Estrutura básica de uma rede neural de Kohonen.

Os mapas topológicos informam como estarão organizados espacialmente os neurônios da rede frente ao comportamento de seus vizinhos, sendo que normalmente são formados por uma dimensão (*array*) ou duas dimensões (*grade*). Para o exemplo da Figura 8 se observa um mapa bidimensional, constituído por 63 neurônios. Nota-se que os neurônios são espacialmente dispostos em linhas e colunas. Definido o mapa topológico da rede, deve-se especificar o critério de vizinhança interneurônios que indique como estarão cooperando em relação aos seus vizinhos (SILVA, SPATTI e FLAUZINO, 2010).

O processo de treinamento da rede neural de Kohonen consiste principalmente em três etapas: competição, cooperação e adaptação. Na primeira etapa, competição, os neurônios competem para serem ativados, e modo que apenas o neurônio que possuir uma maior relação com a entrada será ativo. Após obter-se o neurônio vencedor são selecionados os seus vizinhos, esses serão os neurônios que terão os pesos sinápticos atualizados. Os demais neurônios permanecem com os mesmos pesos. Para se garantir a qualidade do mapa auto-organizável é necessário que todos os neurônios do mapa sejam expostos a um número razoável de padrões (YANG, HAN e AN, 2004) (HAYKIN, 1999).

Como os mapas auto-organizáveis não possuem durante o treinamento as saídas desejadas, classes, é necessário o uso de ferramentas estatísticas e de conhecimento especialista, para se identificar as possíveis classes que agrupam os dados de características semelhantes. Desse modo, o mapa topológico pode ser particionado, após o treinamento, em regiões que definem as respectivas classes, determinando assim um mapa de contexto. A Figura 9 ilustra um potencial mapa de contexto para a topologia bidimensional proposta. Desta forma, quando uma amostra for apresentada a rede para ser classificada, primeiro se

verifica qual foi o neurônio vencedor da competição. Na sequência, recorre-se ao mapa de contexto com a finalidade de identificar a qual classe a amostra pertence (SILVA, SPATTI e FLAUZINO, 2010).




Figura 9 – Exemplo de mapa de contexto de três classe.

2.8.2.1 Processo de aprendizado competitivo

Para descrever os passos envolvidos com o processo de aprendizado competitivo utilizado na rede de Kohonen, considera-se uma estrutura neural constituída de apenas uma camada neural, conforme ilustrada na Figura 10. As conexões laterais entre os neurônios assumem aqui o papel de que um neurônio pode influenciar na resposta de saída produzida por outro neurônio.




Figura 10 – Estrutura neural básica de uma rede competitiva (SILVA, SPATTI e FLAUZINO, 2010).

Segundo (SILVA, SPATTI e FLAUZINO, 2010), o princípio básico para o processo de aprendizado competitivo é a concorrência entre os neurônios, tendo-se o objetivo de se sair vencedor da prova de competição, pois se ressalta que aqui o processo é não supervisionado. O prêmio para aquele que venceu a competição com os outros neurônios será o ajuste de seus

pesos, proporcionalmente aos valores do padrão de entrada apresentado, visando-se assim aperfeiçoar o seu estado para a próxima competição.

Considerando tal contexto, haveria, portanto, a necessidade de se estabelecer uma regra que defina quem vai ser o neurônio vencedor. Uma das medidas mais utilizadas consiste em determinar o nível de proximidade existente entre o vetor de pesos de cada neurônio, frente ao vetor de entrada de uma amostra, a qual será apresentada a rede. Uma métrica de proximidade normalmente usada é a distância entre esses dois parâmetros (SILVA, SPATTI e FLAUZINO, 2010) (HAYKIN, 1999).

$$dist_j^{(k)} = \sqrt{\sum_{i=1}^n (x_i^{(k)} - w_i^{(j)})^2}, \text{ onde } j = 1, \dots, n_1 \quad (20)$$

onde $dist_j^{(k)}$ quantifica a distância (norma euclidiana) entre o vetor de entrada, representando a k-ésima amostra ($x^{(k)}$), em relação ao vetor de pesos do j-ésimo neurônio ($w^{(j)}$).

Assim, aquele neurônio que obtiver a menor distância será declarado o vencedor, e terá seu vetor de pesos ajustados de maneira que este se aproxime ainda mais daquela amostra. Para tanto, utiliza-se o seguinte método de adaptação:

$$w_{atual}^{(v)} = w_{anterior}^{(v)} + \eta \cdot (x^{(k)} - w_{anterior}^{(v)}) \quad (21)$$

onde $w^{(v)}$ denota o vetor de pesos do neurônio vencedor e o parâmetro η define a taxa de aprendizagem.

Após a convergência do algoritmo competitivo, cada um dos vetores de pesos dos neurônios estará posicionado nos centros dos aglomerados (*clusters*) que possuem características comum. Tais aglomerados representarão as respectivas classes associadas ao problema de classificação de padrões, sendo que a quantidade destas ficará automaticamente vinculada ao número de neurônios utilizados na estrutura neural.

CAPITULO 3 - MATERIAIS E MÉTODOS

Este capítulo abordará os equipamentos e a metodologia utilizada na realização dos ensaios de dressagem, bem como a forma de configurar e implementar os modelos neurais.

Os ensaios foram realizados no Laboratório de Usinagem por Abrasão (LUA) da Faculdade de Engenharia de Bauru (FEB) da Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP).

3.1 MONTAGEM DO BANCO DE ENSAIOS

Para a realização dos ensaios foi utilizada uma máquina retificadora plana tangencial da Sulmecânica modelo 1055E. A retificadora foi equipada com um rebolo de abrasivo convencional de óxido de alumínio, com ligante vitrificado, dureza L - média -, granulometria de 150 - muito fina - e estrutura com dimensões 355,6x25,4x127 mm.

Foram utilizados dressadores de três qualidades diferentes da marca Royall Diamond, com as características dos diamantes observadas na Tabela 1. O formato dos dressadores utilizados é ilustrado pela Figura 11. A fixação dos dressadores à mesa retificadora foi realizada utilizando-se um suporte metálico, que serviu também para a fixação do sensor de EA.

Tabela 1 - Características dos dressadores utilizados.

Diamante	Marcação	Tipo
Royall CVD - Vale	7P	Sintético
Royall Mato Grosso	10P	Natural
Royall Brasil Extra	20P	Natural



Figura 11 - Formato dos dressadores utilizados.

A aquisição do sinal da emissão acústica foi realizada por um sensor do tipo piezelétrico de alta sensibilidade da marca Sensis. O sinal do sensor foi condicionado para aquisição através de um módulo de processamento de EA modelo DM42 da fabricante Sensis, o qual permite a aquisição dos sinais puros e RMS.

Na Figura 12 é apresentado de forma esquemática a montagem dos equipamentos e o processo de aquisição de dados.

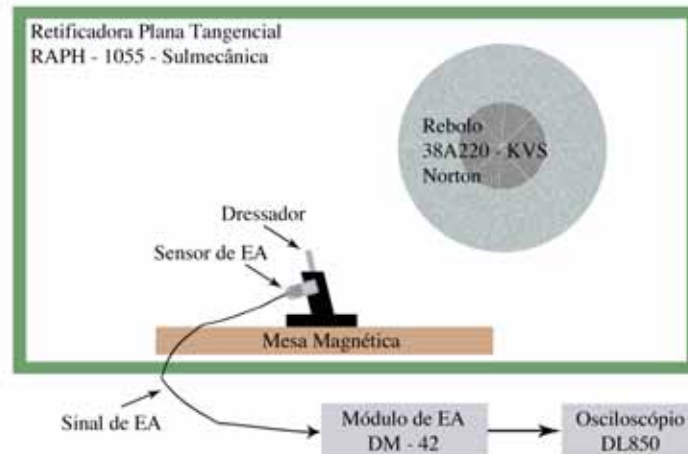


Figura 12 - Esquema da montagem do banco de ensaios.

3.1.1 CONFIGURAÇÃO DOS PARÂMETROS DE DRESSAGEM

Os parâmetros de dressagem foram adequadamente controlados para assegurar que todos os ensaios apresentassem condições semelhantes. Dentre os principais parâmetros utilizados tem-se a velocidade transversal do rebolo, que foi mantida constante e igual a 3,45 mm/s, a profundidade de dressagem (a_d) de 40 μm que foi constante, e o U_d igual a 1 no início da dressagem. Todos os parâmetros estão compilados na Tabela 2.

Tabela 2 - Parâmetros de dressagem empregados nos ensaios.

Parâmetro	Especificação
Refrigeração	Sem fluido de corte
Rebolo	Tipo: 38A220KVS Abrasivo: Convencional de óxido de alumínio Ligante: Vitrificado Dureza: L Granulometria: 150 Dimensões: 355,6x25,4x127 mm Rotação: 1790 RPM V_s : 33,3 m/s
Profundidade de dressagem	40 μm
Velocidade transversal do dressador	3,45 mm/s
U_d no início do ensaio	1

3.1.2 SISTEMA DE AQUISIÇÃO DE IMAGENS

Para realizar as medições do desgaste da ponta dos dressadores foi utilizado um microscópio estereoscópico modelo CITOVAL 2 com ampliações de 10x a 100x da marca Carl Zeiss Predstavnistvo Beograd (Montenegro); a ampliação adotada para a tomada das imagens foi de 16x. Acoplada a este microscópio estava uma câmera EC 3 da LEICA. A Figura 13 apresenta esses equipamentos.



(a)



(b)

Figura 13 - Sistema de aquisição de imagens: (a) microscópio estereoscópico com a câmera acoplada; (b) câmera EC 3 em detalhe.

As imagens da ponta dos dressadores foram obtidas para duas posições, uma lateral e outra frontal, como ilustrado pela Figura 14.



Figura 14 - Vistas da ponta do resador: (a) lateral; (b) frontal.

3.1.3 SISTEMA DE AQUISIÇÃO DE DADOS

O sinal de EA foi pré-processado, com o objetivo de reduzir os ruídos e amplificar o sinal para a aquisição. O ajuste do amplificador foi realizado a partir do ganho de entrada do sinal, de modo que o sinal não se apresente com amplitudes muito baixas e não se sature.

Esse sinal foi adquirido na forma pura por um osciloscópio modelo DL850 da Yokogawa, a uma taxa de dois milhões de amostras por segundo.

Os parâmetros utilizados no sistema de aquisição de dados estão na Tabela 3.

Tabela 3 - Parâmetros de configuração do sistema de aquisição de dados.

Parâmetro	Especificação
Tipo de sensor	Passivo
Módulo de EA	Ganho de entrada: 10 Ganho de sinal: 10 Redutor de ruído: 5
Tipo de sinal	Puro
Frequência de amostragem	2 MS/s

3.2 PROCEDIMENTOS DOS ENSAIOS

Após a montagem do banco de ensaios e configurações dos equipamentos foi realizada a coleta dos sinais e as medições de desgaste dos dressadores. Cada dressador foi utilizado até o final da sua vida útil, que foi definida como o momento em que o corpo metálico do dressador entrava em contato com o rebolo, caracterizado por um faiscamento durante a operação.

Para cada passada (uma ida e uma volta) do rebolo sobre o dressador foi gerado um arquivo binário do sinal puro de EA. Após uma passada o rebolo era avançado em 40 μm em direção ao dressador, ou seja, a penetração do dressador foi de 40 μm por passada. Para cada tipo de dressador, três ensaios foram realizados com paradas para medições do desgaste e um sem paradas. O desgaste do dressador foi medido a cada 20 passadas (800 μm de penetração). Os ensaios sem medições do desgaste teve como objetivo gerar informações para o processamento de sinais sem a influência das paradas no sinal de EA coletado.

Durante o experimento o rebolo foi trocado a cada três ensaios, para se manter a diferença entre a velocidade periférica inicial e a final em um valor aceitável. Adicionalmente, os dressadores foram ensaiados de forma alternada, ou seja, ora para um tipo de dressador ora para outro, de maneira que a variação da velocidade periférica decorrente da diminuição do raio do rebolo ocorresse em todos os tipos de dressadores.

3.3 AQUISIÇÃO DOS DADOS DE DESGASTE DO DRESSADOR

As imagens obtidas da ponta dos dressadores foi analisada utilizando-se o programa LEICA Application Suite LAS EZ versão 1.6.0 (*build* 2601). Nessa etapa foram tomadas as medidas das arestas do diamante. Utilizando um *software* estilo *CAD* foi possível calcular aproximadamente a área desgastada do diamante. Com base nesses dados foi possível determinar a tendência de desgaste dos diamantes.

A Figura 15 ilustra a evolução do desgaste do dressador CVD durante todo o ensaio - (a) vista lateral e (b) vista frontal.




Figura 15 - Evolução do desgaste do dressador CVD - (a) vista lateral. (b) vista frontal.

3.4 PROCESSAMENTO DO SINAL DE EMISSÃO ACÚSTICA

Após a realização de todos os ensaios e de posse dos arquivos dos sinais de emissão acústica foi realizado o processamento digital desses sinais no programa MATLAB. Inicialmente foi relacionado o desgaste da ferramenta com o valor médio do sinal RMS de

EA. Na Figura 16 se pode observar o sinal puro e o sinal RMS de uma passada de um ensaio do dressador CVD.




Figura 16 - Sinal puro (a) e sinal RMS (b) de EA para uma passada do ensaio do dressador CVD.

O primeiro processamento realizado foi a identificação das passadas onde não ocorreu a operação de dressagem. Para algumas passadas do ensaio, mesmo com o avanço de 40 μm , o contato dressador/rebolo não foi uniforme durante toda a passada, apresentando apenas uma pequena área de contato. A Figura 17 apresenta uma passada com contato uniforme e uma passada que apresentou contato incompleto.




Figura 17 - Passada com contato consistente (a); Passada com contato incompleto (b).

Como esses dados não representaram um desgaste significativo do dressador puderam ser desconsiderados na análise das estatísticas geradas. O processo de identificação foi realizado de forma automática, utilizando-se de base à amplitude da atividade acústica e o tempo de duração da passada.

Após a seleção das passadas válidas para análise, foi realizado um estudo do espectro de frequência do sinal puro de EA para diferentes momentos do ensaio. Neste estudo nove regiões foram observadas, ou seja, bandas de frequências que apresentavam características interessantes para a identificação do nível de desgaste do dressador. Essas bandas foram escolhidas por apresentarem variações consideráveis na atividade acústica de acordo com o nível de desgaste, de modo que fosse possível caracterizar a condição do dressador. Dessa forma, cada passada do ensaio pode ser representada por um vetor de nove pontos correspondentes aos valores médios do sinal RMS obtido para cada banda de frequência. A Figura 18 ilustra o processo de obtenção das curvas características que serviram de entrada para os modelos neurais.

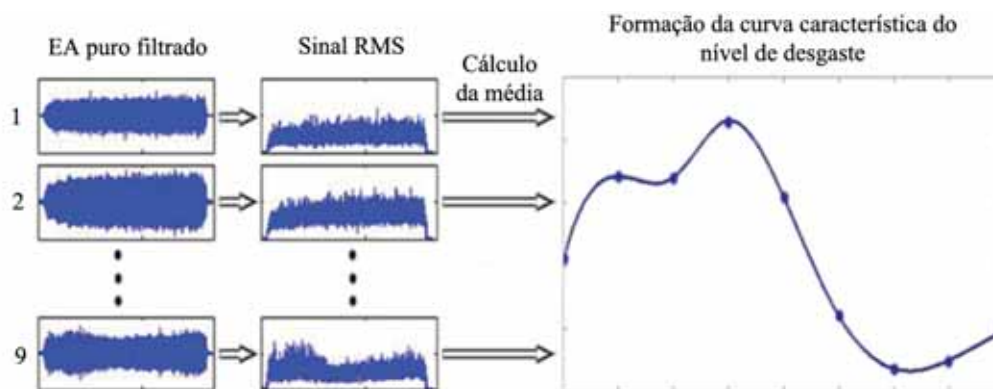


Figura 18 - Processo de tratamento do sinal de EA.

3.5 MODELOS NEURAI

Estudou-se a utilização de dois tipos de redes neurais, a Rede Neural Perceptron de Múltiplas Camadas (MLP - do inglês, *Multi-Layer Perceptron*) e a Rede Neural de Kohonen, para a classificação do desgaste da ferramenta de dressagem. Para cada tipo de rede foram testados vários modelos com o objetivo de se atingir o menor erro de classificação.

Os modelos neurais testados tiveram como entradas o valor médio RMS e ROP do sinal puro filtrado em nove bandas de frequência. A princípio as estatísticas RMS e ROP foram utilizadas independentemente, isso é, para cada um delas foi processado uma sequência de testes para obtenção da melhor configuração. Nestes testes foram obtidos os melhores modelos para que as nove bandas de frequência fossem usadas como entradas dos modelos bem como a combinação de duas melhores dessas bandas. Tendo-se as melhores bandas para cada uma das estatísticas, estas foram combinadas, obtendo-se assim modelos com as entradas compostas pelas estatísticas RMS e ROP.

Os modelos utilizados apresentavam três saídas, indicando qual nível de desgaste (N - novo; MV - meia vida; D - desgastado) pertencia os valores apresentados à entrada da rede.

3.5.1 TREINAMENTO DOS MODELOS NEURAIIS

Para realizar o treinamento da rede neural foi utilizado um conjunto de dados de 1500 valores, sendo que cada nível de desgaste era representado por 500 valores. Para a obtenção de cada um dos conjuntos de 500 valores, foram selecionadas 5 passadas pertencentes a cada um dos níveis de desgaste. Estas passadas foram divididas em cem trechos, de mesmo comprimento, que foram processados. Assim, foi possível obter uma massa de dados significativa para o treinamento dos modelos neurais.

O algoritmo desenvolvido para testar os modelos neurais é ilustrado pelo fluxograma da Figura 19. Dado um conjunto de entrada, o teste era conduzido realizando-se a combinação das entradas segundo uma tabela com os padrões que deveriam ser utilizados. Definida as entradas, o conjunto era dividido aleatoriamente em dois conjuntos, um de 80% usado no treinamento e outro de 20% usado para verificação da rede. O conjunto de treinamento era novamente dividido, agora 60% para treinamento, 20% para validação e 20% para teste, correspondentes aos conjuntos utilizados nas rotinas de treinamento da RNA.

A cada iteração do algoritmo, novos parâmetros eram testados de acordo com o tipo de RNA que estava sendo utilizada. Na Tabela 4 é possível observar os parâmetros utilizados para os modelos neurais MLP, e na Tabela 5 os parâmetros para os modelos neurais de Kohonen.

Tabela 4 - Parâmetros de configuração da rede neural MLP.

Parâmetro	Especificação
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>
Número máximo de falhas de validação	15
Número máximo de épocas	2000
Quantidade de camadas ocultas	Variável: 1; 2; 3
Quantidade de neurônios por camada oculta	Variável: 5; 10; 15; 20; 40

Tabela 5 - Parâmetros de configuração da rede neural de Kohonen.

Parâmetro	Especificação
Função de treinamento	<i>Batch Weight/Bias Rules</i>
Número máximo de épocas	1000
Estrutura	Mapa variável: 5 x 5 à 15 x 15

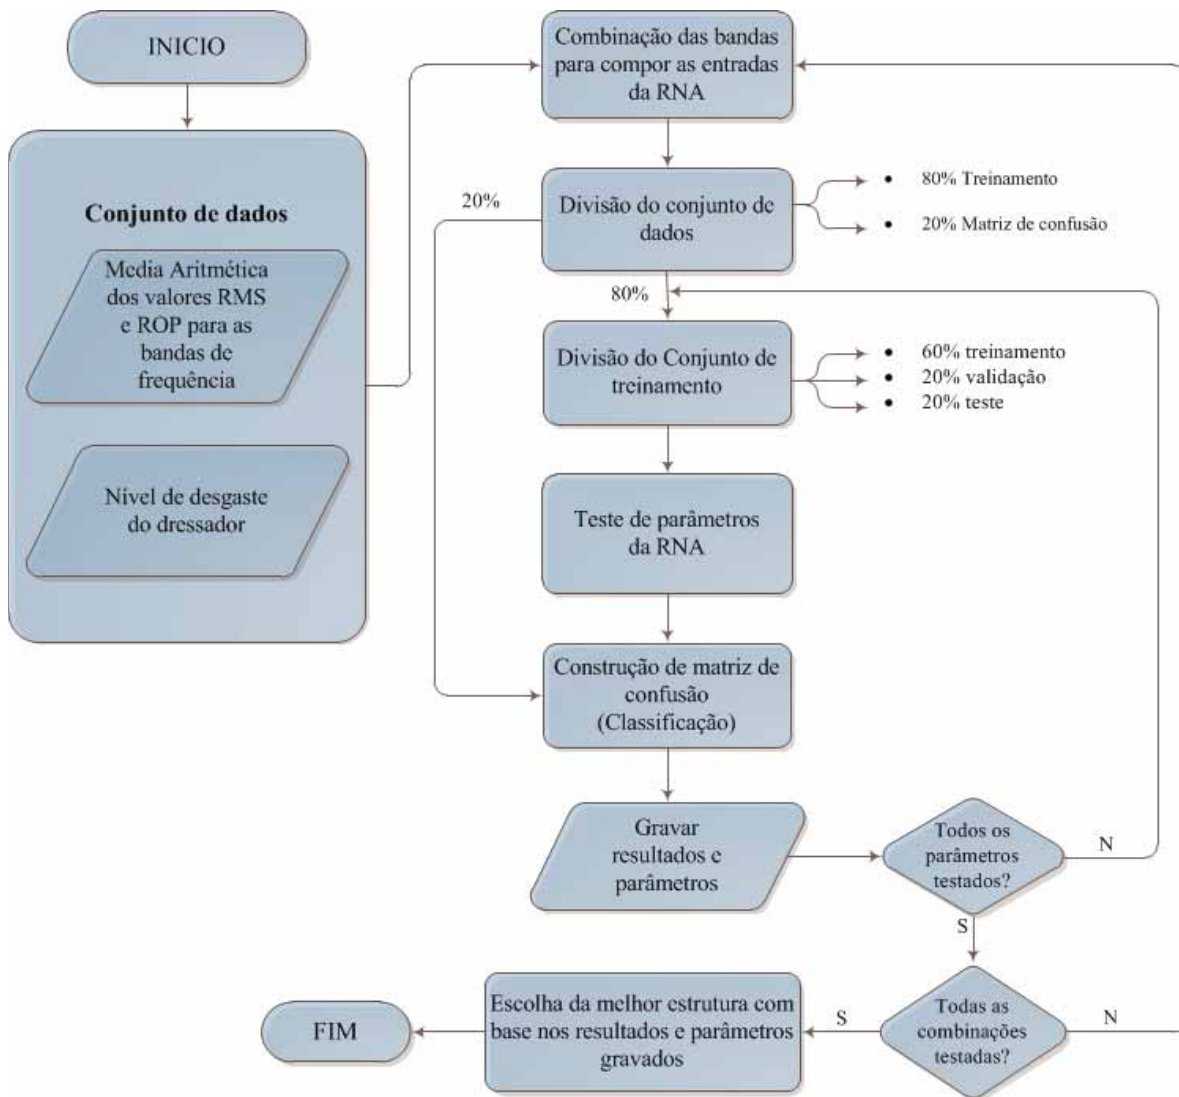


Figura 19 - Fluxograma do algoritmo de teste dos modelos neurais.

Realizado o treinamento do modelo neural, o erro de classificação desse modelo foi calculado com base no conjunto de dados de 20% separado para verificação, e os resultados mostrados em uma matriz de confusão. O valor do erro e os parâmetros utilizados no modelo eram então armazenados, e um novo teste era realizado. Com o objetivo de se testar a estabilidade de um conjunto de configurações, o mesmo era utilizado no treinamento de cinco redes neurais, sendo calculado o desvio padrão de cada treinamento.

Após a realização de todos os testes, os modelos neurais eram organizados de acordo com o erro e o desvio padrão observados nas cinco repetições; dessa forma, os modelos escolhidos foram aqueles que apresentaram o menor erro e desvio padrão.

CAPITULO 4 - RESULTADOS E DISCUSSÕES

4.1 DESGASTE DOS DIAMANTES

Nessa seção serão apresentados os dados obtidos da análise das fotos dos dressadores e as suas áreas desgastadas.

4.1.1 DIAMANTE CVD

A partir de observações realizadas nas imagens da vista lateral do dressador CVD foi possível determinar a sua área desgastada. Os dados obtidos para os três ensaios realizados estão dispostos na Tabela 6.

Tabela 6 - Dados de área desgastada obtidos para os ensaios dos diamantes CVD a partir da vista lateral.

Número da passada	Área desgastada x 10 ⁻³ (mm ²)		
	Ensaio 01	Ensaio 02	Ensaio 03
20	5,72	17,56	17,38
40	12,43	42,33	30,23
60	18,77	56,51	33,15
80	25,68	54,17	46,56
100	34,24	82,49	47,34
120	44,22	88,59	55,37
140	52,58	94,96	59,24
160		111,43	61,82
180		112,53	73,03
200		351,14	
220		446,27	
240		517,12	
260		739,41	
280		1033,52	

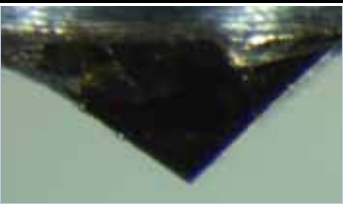
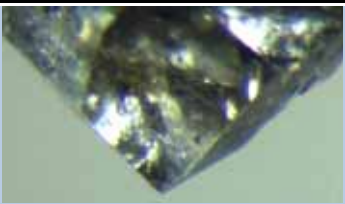

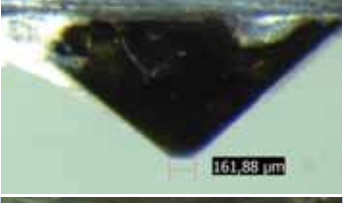

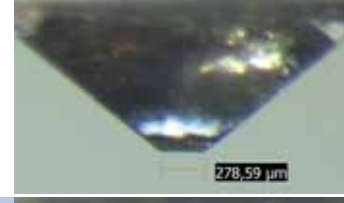

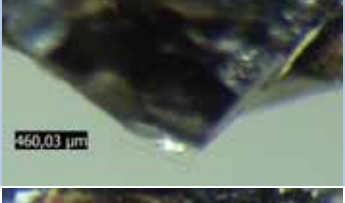
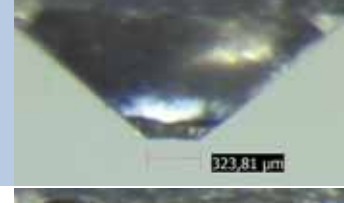

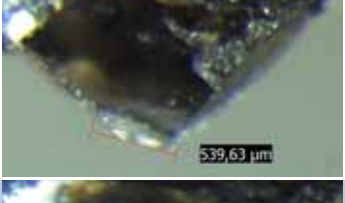
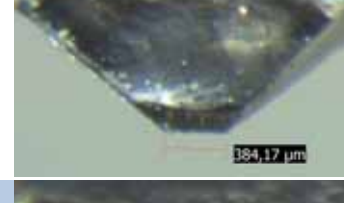
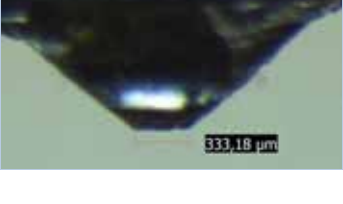
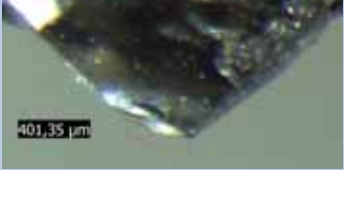

Devido à presença de impurezas nos diamantes, os ensaios não apresentaram a mesma quantidade de passadas. Dessa forma, para se realizar uma análise do desgaste tendo repetição dos dados para o cálculo da média e do desvio padrão para cada medição, foi adotado o total de passadas do menor ensaio como quantidade máxima de passadas. Dessa forma, as passadas até o limite de 140 foram consideradas para análise das áreas para o diamante CVD. Assim, a Tabela 7 apresenta os valores médios das áreas desgastadas e seus desvios padrão para cada 20 passadas.

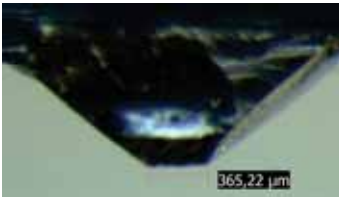
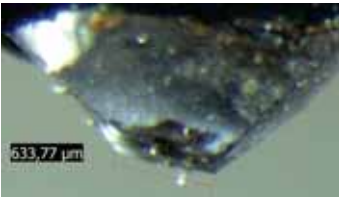
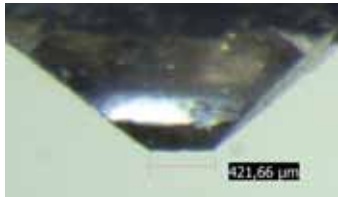
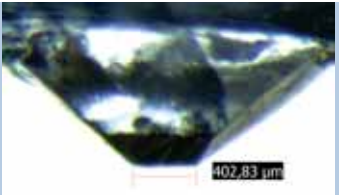
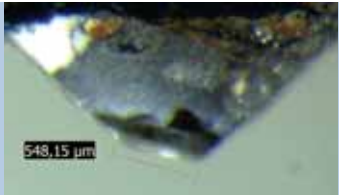
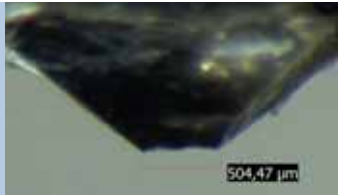

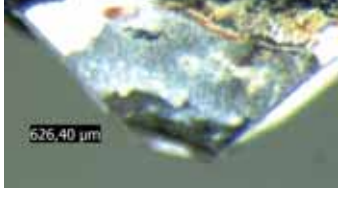
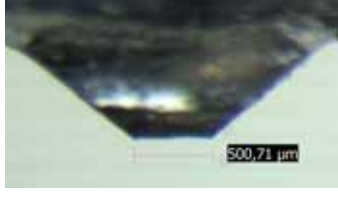
Tabela 7 - Área desgastada média do diamante CVD, para vista lateral.

Número da passada	Área desgastada média x 10 ⁻³ (mm ²)	Desvio padrão x 10 ⁻³ (mm ²)
20	13,55	5,54
40	28,66	11,85
60	36,14	15,55
80	42,14	12,05
100	54,69	20,38
120	62,72	18,85
140	68,93	18,61

Na Tabela 8 estão as fotos referentes aos desgastes dos três ensaios até a passada limite de 140.

Tabela 8 - Imagens de referência para o cálculo da área desgastada do diamante CVD, para vista lateral.

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
0			
20			
40			
60			
80			

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
100			
120			
140			

A Figura 20 foi obtida a partir da Tabela 7 e pode se observar que existe certa linearidade entre os dados, com o desvio padrão indicando a dispersão dos dados. O coeficiente angular da reta, que se aproxima das áreas medidas, foi de 0,53, significando que a cada passada, em média, 0,53 mm² de área será desgastada do diamante.

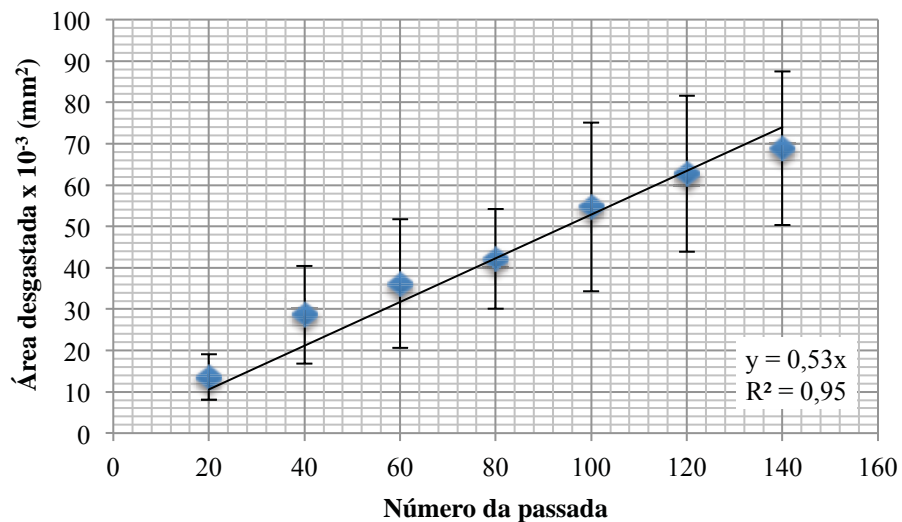


Figura 20 - Área desgasta por quantidade de passadas para o diamante CVD, para vista lateral.

Este mesmo procedimento foi realizado na análise da vista frontal do diamante CVD, sendo obtida a Tabela 9 de dados. A partir dessa tabela, os ensaios foram limitados a 140

passadas, compondo a média da área desgastada e o desvio padrão para cada medição do desgaste, conforme mostra a Tabela 10.

Tabela 9 - Dados de área desgastada obtidos para os ensaios dos diamantes CVD a partir da vista frontal.

Número da passada	Área desgastada x 10 ⁻³ (mm ²)		
	Ensaio 01	Ensaio 02	Ensaio 03
20	49,34	41,69	124,52
40	110,81	126,95	212,32
60	169,12	196,80	263,86
80	241,13	262,54	325,63
100	303,01	324,07	349,63
120	359,32	390,08	539,88
140	380,94	423,46	565,85
160		470,99	658,31
180		685,21	707,66
200		1420,34	817,56
220		1701,80	
240		2043,10	
260		2625,62	
280		3031,27	

Tabela 10 - Área desgastada média do diamante CVD, para vista frontal.

Número da passada	Área desgastada média x 10 ⁻³ (mm ²)	Desvio padrão x 10 ⁻³ (mm ²)
20	71,85	37,37
40	150,02	44,54
60	209,93	39,77
80	276,43	35,87
100	325,57	19,06
120	429,76	78,88
140	456,75	79,08

A Figura 21 é composta pelos valores apresentados na Tabela 10 e com base nas imagens expostas na Tabela 11. Observa-se uma grande linearidade entre os dados, com um desvio padrão indicando uma dispersão relativamente baixa até a passada número 100 e uma grande dispersão para as passadas seguintes. O coeficiente angular da reta de aproximação encontrada é de 3,40, ou seja, 3,40 mm² de área gasta no diamante por passada.


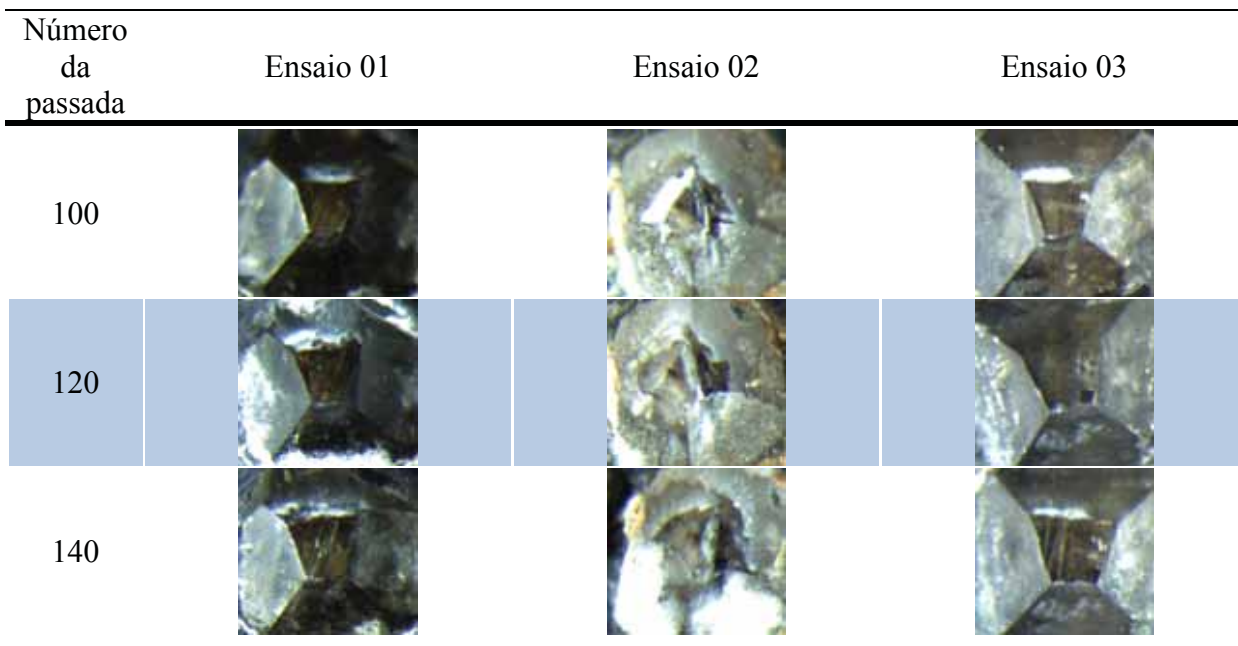


Figura 21 - Área desgasta por quantidade de passadas para o diamante CVD, para vista frontal.

Tabela 11 - Imagens de referência para o cálculo da área desgastada do diamante CVD , para vista frontal.

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
0			
20			
40			
60			
80			



4.1.2 DIAMANTE MATO GROSSO

Tendo como base as imagens de microscópio dos dressadores foi possível determinar a área desgasta em cada um dos ensaios. Os dados obtidos para os ensaios dos dressadores com ponta de diamante do tipo Mato Grosso estão apresentados na Tabela 12.

Tabela 12 - Dados de área desgastada obtidos para os ensaios dos diamantes Mato Grosso, para vista lateral.

Número da passada	Área desgastada x 10 ⁻³ (mm ²)		
	Ensaio 01	Ensaio 02	Ensaio 03
20	35,27	15,63	38,03
40	52,47	32,15	48,14
60	80,14	38,99	78,37
80	92,19	52,78	156,31
100	112,28	62,48	286,73
120	132,39	83,57	
140	186,44	87,20	
160		90,85	
180		121,17	

Para se determinar a área desgastada média e o respectivo desvio padrão para cada passada de medição, foi estipulado como limite o total de passadas do menor ensaio. Dessa forma, para os ensaios do diamante Mato Grosso foi adotado o limite de 100 passadas. Na Tabela 13 é apresentada a área desgastada média e o desvio padrão desse diamante.

Tabela 13 - Área desgastada média do diamante Mato Grosso, para vista lateral.

Número da passada	Área desgastada média x 10 ⁻³ (mm ²)	Desvio padrão x 10 ⁻³ (mm ²)
20	29,65	9,97
40	44,25	8,74
60	65,83	18,99
80	100,43	42,67
100	153,83	96,15

A partir dos dados da Tabela 13 foi possível gerar a Figura 22. Com a análise desse gráfico e das imagens expostas na Tabela 14 se observa uma linearidade entre os dados de desgaste, porém o desvio padrão indica uma grande dispersão dos dados para as passadas 80 e 100. O coeficiente angular da reta de aproximação encontrada é de 1,35, o que representa um desgaste de 1,35 mm² por passada.


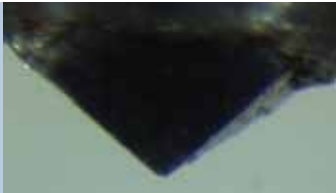
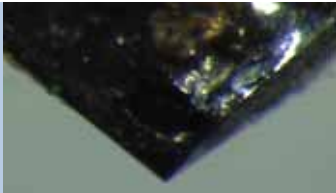
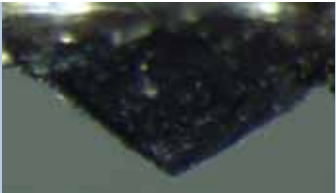
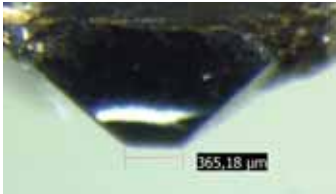
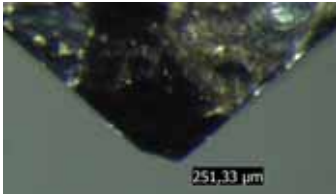
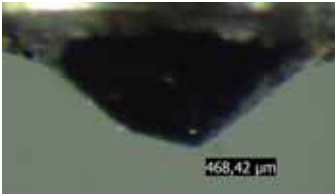
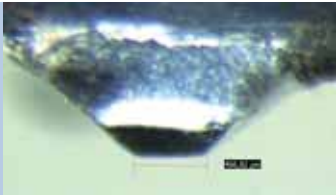
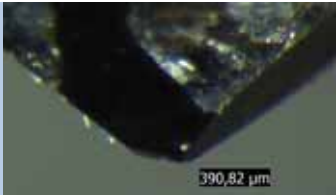
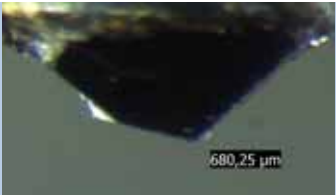
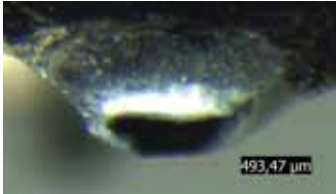
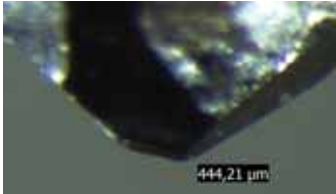
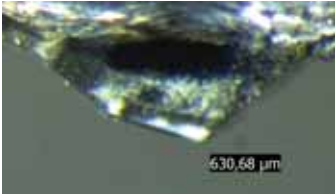
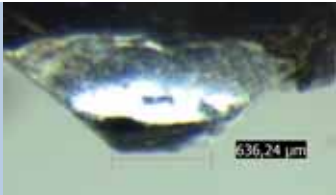
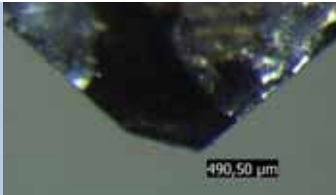
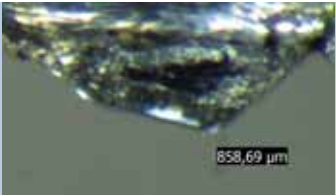
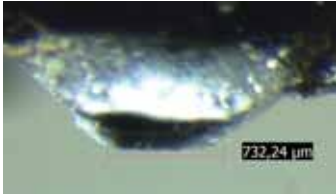
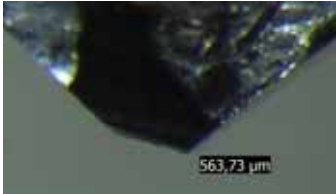



Figura 22 - Área desgastada por passada para o diamante Mato Grosso, para vista lateral.

Tabela 14 - Imagens de referência para o cálculo da área desgastada do diamante Mato Grosso, para vista lateral.

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
0			
20			
40			
60			
80			
100			

Este mesmo procedimento foi realizado na análise da vista frontal do diamante Mato Grosso, sendo obtida a Tabela 15 de dados. A partir dessa tabela os ensaios foram limitados a 100 passadas, compondo a média da área desgastada e o desvio padrão para cada medição do desgaste, conforme mostra a Tabela 16.

Tabela 15 - Dados de área desgastada obtidos para os ensaios dos diamantes Mato Grosso, para vista frontal.

Número da passada	Área desgastada x 10 ⁻³ (mm ²)		
	Ensaio 01	Ensaio 02	Ensaio 03
20	290,15	65,56	168,65
40	396,05	128,36	254,38
60	484,02	190,99	346,57
80	645,56	245,49	549,58
100	684,57	287,02	670,06
120	701,41	340,92	
140	888,05	374,70	
160		428,14	
180		516,53	

Tabela 16 - Área desgastada média do diamante Mato Grosso, para vista frontal.

Número da passada	Área desgastada média x 10 ⁻³ (mm ²)	Desvio padrão x 10 ⁻³ (mm ²)
20	174,79	91,79
40	259,60	109,35
60	340,53	119,71
80	480,21	170,53
100	547,22	184,08

A Figura 23 representa graficamente os dados da Tabela 16. Analisando esse gráfico e as imagens da superfície do diamante, Tabela 17, observa-se uma linearidade no desgaste do diamante, porém o desvio padrão mostra uma grande dispersão nos dados. O coeficiente angular da reta de aproximação encontrada é de 5,79. Isso indica que o diamante sofre um desgaste de 5,79 mm² por passada.


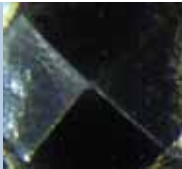
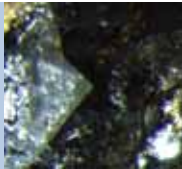
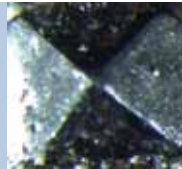

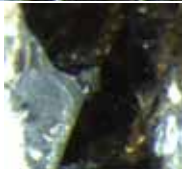
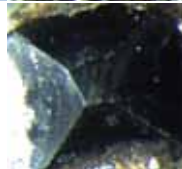
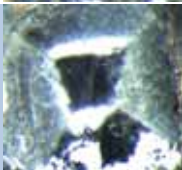

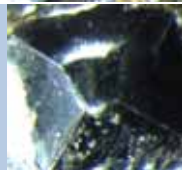


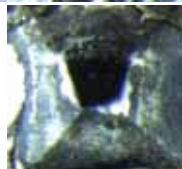








Figura 23 - Área desgastada por passada para o diamante Mato Grosso, para vista frontal.

Tabela 17 - Imagens de referência para o cálculo da área desgastada do diamante Mato Grosso, para vista frontal.

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
0			
20			
40			
60			
80			
100			

4.1.3 DIAMANTE BRASIL EXTRA

Tendo como base as imagens de microscópio dos dressadores, foi possível determinar a área desgasta em cada um dos ensaios. Os dados obtidos para os ensaios dos dressadores com ponta de diamante do tipo Brasil Extra estão apresentados na Tabela 18.

Tabela 18 - Dados de área desgastada obtidos para os ensaios dos diamantes Brasil Extra, para vista lateral.

Número da passada	Área desgastada x 10 ⁻³ (mm ²)		
	Ensaio 01	Ensaio 02	Ensaio 03
20	3,33	16,19	16,24
40	11,29	32,46	26,86
60	16,31	44,64	31,84
80	18,60	74,97	46,95
100	24,15	116,63	49,89
120	31,04	148,67	
140	40,65	299,87	
160	51,05	471,70	
180	101,57		

Para se determinar a área desgastada média e o respectivo desvio padrão para cada passada de medição, foi estipulado como limite o total de passadas do menor ensaio. Dessa forma, para os ensaios do diamante Mato Grosso foi adotado o limite de 100 passadas. Na Tabela 19 é apresentada a área desgastada média e o desvio padrão desse diamante.

Tabela 19 - Área desgastada média do diamante Brasil Extra, para vista lateral.

Número da passada	Área desgastada média x 10 ⁻³ (mm ²)	Desvio padrão x 10 ⁻³ (mm ²)
20	11,92	6,07
40	23,54	8,96
60	30,93	11,59
80	46,84	23,01
100	63,56	38,97

A partir dos dados da Tabela 19 é possível obter o gráfico mostrado na Figura 24. Com a análise dessa figura e das imagens expostas na Tabela 20 se observa linearidade entre os dados de desgaste, porém o desvio padrão indica uma dispersão crescente dos dados ao longo das passadas, com valor bem significativo a partir da passada 80. O coeficiente angular da reta de aproximação encontrada é de 0,60, representando um desgaste de 0,60 mm² por passada.


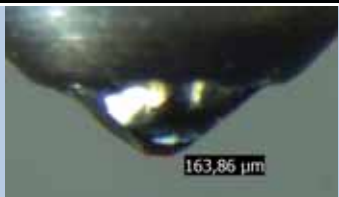

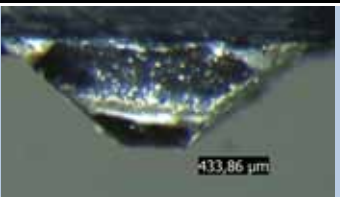
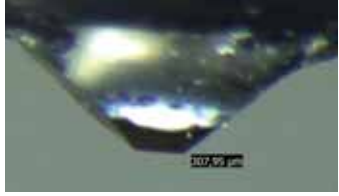
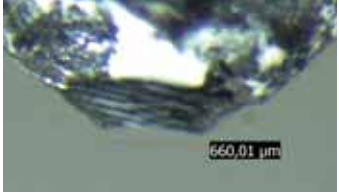
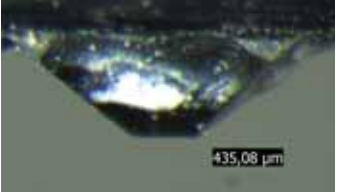


Figura 24 - Área desgastada por passada para o diamante Brasil Extra, para vista lateral.

Tabela 20 -Imagens de referência para o cálculo da área desgastada do diamante Brasil Extra, para vista lateral.

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
0			
20	 131,78 µm	 278,55 µm	 252,16 µm
40	 203,33 µm	 383,14 µm	 326,09 µm
60	 241,41 µm	 460,05 µm	 362,66 µm

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
80			
100			

Este mesmo procedimento foi realizado na análise da vista frontal do diamante Brasil Extra, sendo obtida a Tabela 21 de dados. A partir dessa tabela os ensaios foram limitados a 100 passadas, compondo a média da área desgastada e o desvio padrão para cada medição do desgaste, conforme mostra a Tabela 22.

Tabela 21 - Dados de área desgastada obtidos para os ensaios dos diamantes Brasil Extra, para vista frontal.

Número da passada	Área desgastada x 10 ⁻³ (mm ²)		
	Ensaio 01	Ensaio 02	Ensaio 03
20	27,39	27,13	97,43
40	75,14	51,55	160,06
60	106,36	152,71	243,04
80	158,98	188,62	304,65
100	231,70	297,49	355,06
120	288,11	398,05	
140	393,77	465,80	
160	473,45	532,47	
180	644,79		

Tabela 22 - Área desgastada média do diamante Brasil Extra, para vista frontal.

Número da passada	Área desgastada média x 10 ⁻³ (mm ²)	Desvio padrão x 10 ⁻³ (mm ²)
20	50,65	33,08
40	95,58	46,60
60	167,37	56,75
80	217,42	62,86
100	294,75	50,40

A Figura 25 representa graficamente os dados da Tabela 22. Analisando esse gráfico e as imagens da superfície do diamante, Tabela 23, observa-se uma linearidade no desgaste do diamante ao longo das passadas, mas com valores de desvio padrão elevados. O coeficiente angular da reta de aproximação encontrada é de 2,81, indicando que o diamante sofreu um desgaste de 2,81 mm² por passada.


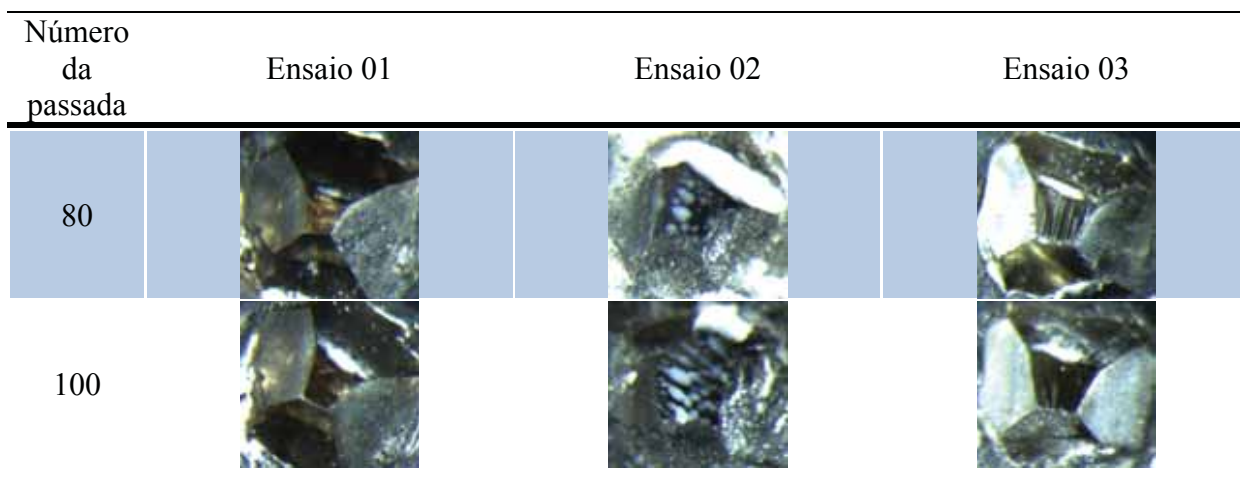


Figura 25 - Área desgastada por passada para o diamante Brasil Extra, para vista frontal.

Tabela 23 - Imagens de referência para o cálculo da área desgastada do diamante Brasil Extra, para vista frontal.

Número da passada	Ensaio 01	Ensaio 02	Ensaio 03
0			
20			
40			
60			



4.1.4 COMPARAÇÕES ENTRE OS TRÊS DIAMANTES

Com o objetivo de realizar uma comparação entre os três diamantes utilizados, os dados médios de desgaste por passada, para a vista lateral, foram dispostos na Tabela 24, e foi gerada a Figura 26.

Tabela 24 - Dados de desgaste da vista lateral para os três diamantes.

		Número da passada						
		20	40	60	80	100	120	140
Área desgastada $\times 10^{-3}$ (mm ²)	CVD	13,55	28,66	36,14	42,14	54,69	62,72	68,93
	Mato Grosso	29,65	44,25	65,83	100,43	153,83	----	----
	Brasil Extra	11,92	23,54	30,93	46,84	63,56	----	----




Figura 26 - Área desgastada por número da passada para os três diamantes, para vista lateral.

Observa-se que os diamantes Brasil Extra e CVD apresentaram um comportamento muito semelhante, sendo que a área desgastada do diamante CVD por passada foi maior que a obtida para o dressador Brasil Extra até a passada 80, quando está relação se inverte. Já o diamante Mato Grosso foi o que apresentou a maior relação área desgastada por passada.

Isto pode ser comprovado pelos coeficientes angulares das retas de aproximação que foram de 0,53 mm²/passada, 1,35 mm²/passada e 0,60 mm²/passada para os dressadores CVD, Mato Grosso e Brasil Extra, respectivamente. Esses coeficientes, portanto, indicam um desgaste maior do que duas vezes para o dressador Mato Grosso.

Esta mesma análise foi realizada para os dados de desgaste da vista frontal dos dressadores, sendo os dados organizados na Tabela 25, e o gráfico comparativo das áreas de desgaste obtido e mostrado e na Figura 27.

Tabela 25 - Dados de desgaste da vista frontal para os três dressadores.

		Número da passada						
		20	40	60	80	100	120	140
Área desgastada x 10 ⁻³ (mm ²)	CVD	71,85	150,02	209,93	276,43	325,57	429,76	456,75
	Mato Grosso	174,79	259,60	340,53	480,21	547,22	----	----
	Brasil Extra	50,65	95,58	167,37	217,42	294,75	----	----

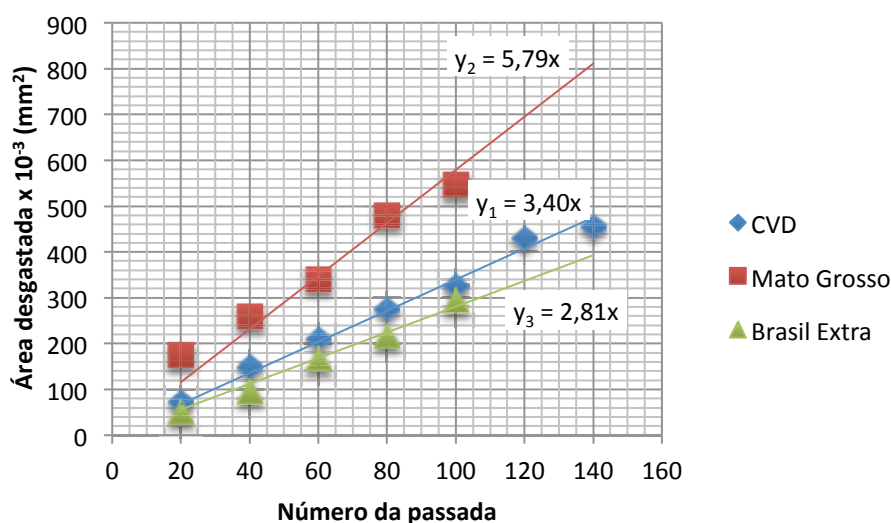


Figura 27 - Área desgastada por número da passada para os três diamantes, para vista frontal.

Nota-se um comportamento semelhante ao observado para a vista lateral, onde o diamante Mato Grosso apresentou um desgaste elevado por passada em comparação aos outros diamantes, enquanto que os diamantes Brasil Extra e CVD apresentaram um comportamento parecido, sendo que o desgaste desse último foi maior que o do Brasil Extra.

Para o processo de classificação do nível de desgaste dos diamantes foram classificadas as passadas até o limite de 20 como dressador novo (N) e como dressador desgastado (D) as passadas em que a área do desgaste lateral ultrapassasse aproximadamente em 4 vezes a área observada na passada de número 20. As passadas situadas entre a passada número 20 e a primeira passada da condição desgastada foram classificadas como dressador com meia vida (MV), indicando que nessa região o diamante ainda apresenta condições de operação.

4.2 PROCESSAMENTO DO SINAL DE EMISSÃO ACÚSTICA

Os sinais coletados foram processados a fim de se obter características nas quais o sinal de EA se correlaciona com o nível de desgaste do dressador. Em uma análise inicial, os valores médios RMS foram calculados para todas as passadas. Logo após esta análise preliminar, foi realizado um estudo do espectro de frequência do sinal puro de EA, que teve como objetivo obter mais informações sobre a condição da ferramenta. Este estudo definiu nove bandas de frequência que foram usadas em filtros passa-banda aplicados ao sinal puro de

EA, e, posteriormente, para o cálculo do valor médio RMS e ROP em cada banda, os quais foram então usados como entradas para os modelos neurais.

4.2.1 ANÁLISE DO VALOR MÉDIO RMS

A partir do sinal puro de EA foi calculado o seu correspondente RMS, do qual foram extraídos os dados correspondentes ao momento em que o dressador esteve em contato com o rebolo, ou seja, a parte válida da passada. O valor médio destes dados equivale a energia média do sinal EA para aquela passada. A Figura 28 ilustra o sinal puro e o seu sinal RMS, destacando-se a passada.




Figura 28 - Identificação da passada. (a) Sinal puro; (b) Sinal RMS com destaque da passada válida.

Nas Figura 29, Figura 30 e Figura 31 podem ser observados os valores médios RMS para os três ensaios de cada dressador, na sequência CVD, Mato Grosso e Brasil Extra. Em cada figura está presente, além do gráfico de cada ensaio, um gráfico com os três ensaios combinados, sendo indicado o desvio padrão dos valores médios para as passadas onde foram realizadas as medições do desgaste.




Figura 29 - Valores médios RMS para o dresser do tipo CVD. (a) Ensaio 01; (b) Ensaio 02; (c) Ensaio 03; (d) Média do dresser.




Figura 30 - Valores médios RMS para o dresser do tipo Mato Grosso. (a) Ensaio 01; (b) Ensaio 02; (c) Ensaio 03; (d) Média do dresser.

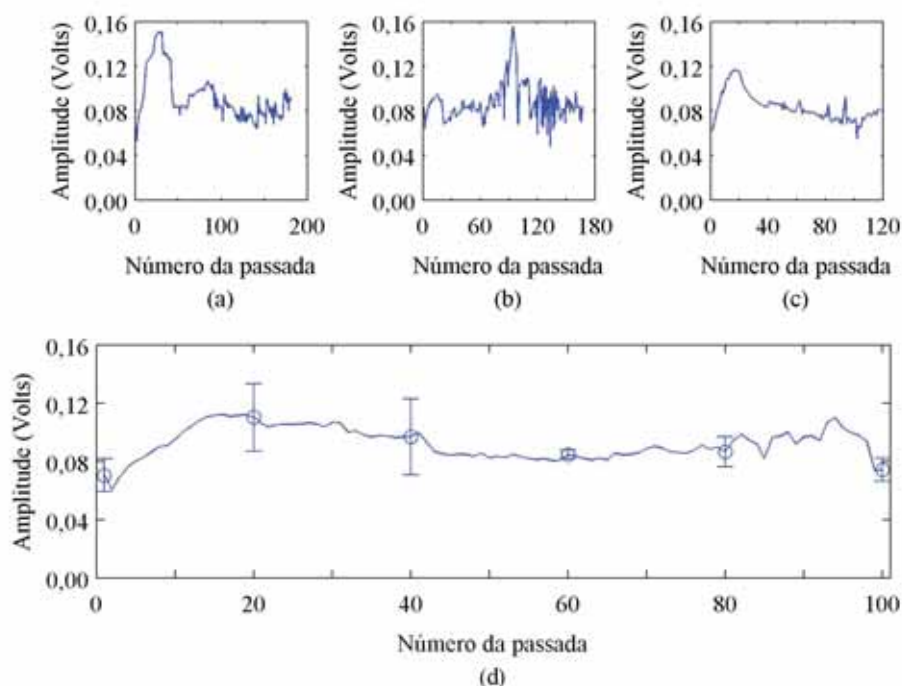


Figura 31 - Valores médios RMS para o dressador do tipo Brasil Extra. (a) Ensaio 01; (b) Ensaio 02; (c) Ensaio 03; (d) Média do dressador.

A partir desses gráficos é possível observar que dentre os ensaios de um determinado tipo de dressador, existem semelhanças quanto à evolução da energia do sinal de EA conforme a ferramenta é desgastada. Alguns comportamentos são semelhantes para tipos de dressadores diferentes, como é o caso do rápido crescimento do valor médio RMS para as primeiras passadas do ensaio. E logo após este crescimento, estes valores estabilizam por algumas passadas e sofrem um leve caimento, mantendo-se com poucas variações ao longo do ensaio. Os desvios padrões observados nos gráficos do item (d) indicaram uma pequena dispersão dos dados, apresentando variações consideráveis para a primeira passada dos ensaios e para as passadas 20 e 40 do dressador Brasil Extra.

Com isso, pode-se verificar que o sinal de EA carrega informações referentes ao nível de desgaste da ferramenta. Porém, o valor médio RMS para todo o espectro de frequência do sinal de EA (nenhum filtro foi aplicado no sinal puro de EA nessa análise) não é capaz de distinguir adequadamente a condição do dressador, devido à proximidade existente entre os dados de classificações diferentes.

4.2.2 ESTUDO DO ESPECTRO DE FREQUÊNCIA DO SINAL DE EA

4.2.2.1 Resposta em Frequência do Sensor de EA

Para se determinar a resposta em frequência do sensor de EA utilizado nos ensaios foi empregado o método da fratura da uma ponta de grafite, como proposto por (HIGO e INABA, 1991). O método consiste em se analisar a resposta em frequência do sensor para um sinal de impulso produzido pela fratura do grafite. Para a realização desse teste foi montado o sistema de aquisição esquematizado na Figura 32. O banco de ensaio para esse teste consistiu de um bloco de aço ABNT 1020, nas dimensões 100 mm de comprimento, 37 mm de largura, e 10 mm de altura, onde foi fixado o sensor de EA, do fabricante Sensis. Uma lapiseira da marca Pentel, 0,5 mm, Grafite 2H, foi posicionada a 30 mm do corpo do sensor de EA, onde se realizou a quebra de 3 mm de ponta do grafite, conforme ilustra a Figura 32.




Figura 32 – Esquema de montagem para o teste da fratura do grafite do sensor de EA.

Para a aquisição do sinal puro de emissão acústica foi utilizado um osciloscópio Yokogawa, modelo DL850, com janela de aquisição de 100 ms e uma taxa de amostragem de 10 milhões de amostras por segundo. Com o objetivo de garantir uma melhor análise dos resultados, o teste foi repetidos três vezes. Na Figura 33 é apresentado o sinal puro obtido para o impulso dos três teste, ao passo que a Figura 34 apresenta o sinal RMS para esses testes.




Figura 33 – Sinal puro do impulso para: (a) Teste 1; (b) Teste 2; (c) Teste 3.




Figura 34 – Sinal RMS do impulso para: (a) Teste 1; (b) Teste 2; (c) Teste 3.

Para o sensor utilizado nesse trabalho, a relação entre a potência do sinal e a frequência obtida para o impulso está representada na Figura 35. Observando-se o espectro de frequência do sinal puro do impulso é possível determinar a resposta do sensor para diferentes frequências.




Figura 35 – Resposta em frequência do sensor de EA.

Nota-se que todos os teste apresentaram um comportamento semelhante, indicando que o sensor responde de forma considerável para as frequências entre 1 kHz e 600 kHz, sendo mais sensível para a frequência de 450 kHz. A partir dessa frequência, o sensor passa a atenuar significativamente o sinal, impossibilitando a análise de frequências mais altas.

4.2.2.2 Análise em Frequência do Sinal Puro de EA

O estudo do espectro de frequência dos sinais de EA teve como objetivo determinar uma correlação entre características desses sinais com o nível de desgaste do dressador. O espectro de frequência foi obtido através da transformada rápida de Fourier (FFT), considerando-se para o cálculo 8192 amostras do sinal pertencentes ao meio da passada.

O espectro de frequência do dressador CVD é apresentado na Figura 36, onde se nota que o sinal de EA apresenta características diferentes no domínio da frequência de acordo com a condição da ferramenta. Observa-se que a atividade acústica nas frequências mais baixas se intensifica conforme o desgaste avança, e esse comportamento se repete para certas frequências médias e altas, onde se vê claramente picos do sinal de EA para as condições de ferramenta com meia vida e desgastada. Esse comportamento é também observado para os dressadores Mato Grosso e Brasil Extra, na Figura 37.




Figura 36 - Espectro de frequência dos três níveis de desgaste do dressador CVD.

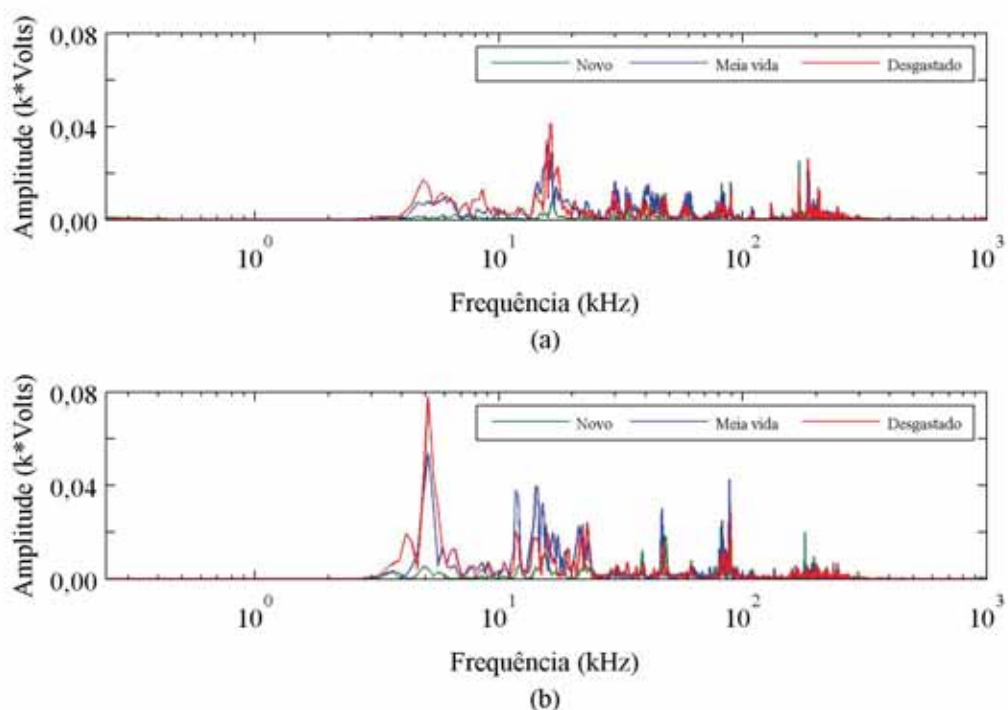


Figura 37 - Espectro de frequência dos três níveis de desgaste dos dressadores: (a) Mato Grosso; (b) Brasil Extra.

Com base nessas observações, bandas de frequência que continham os picos e as regiões onde era visível a diferença entre os níveis de desgaste da ferramenta foram consideradas para estudo. Dessa forma, selecionou-se nove bandas de frequência (denominada a partir de agora de BF1 a BF9), presentes na Tabela 26 e ilustradas pela Figura 38.

Tabela 26 - Bandas de frequência consideradas para estudo.

Identificação	Banda de frequência
BF1	3 - 9 kHz
BF2	12 - 18 kHz
BF3	20 - 26 kHz
BF4	28 - 33 kHz
BF5	42 - 50 kHz
BF6	57 - 68 kHz
BF7	78 - 92 kHz
BF8	191 - 204 kHz
BF9	217 - 223 kHz

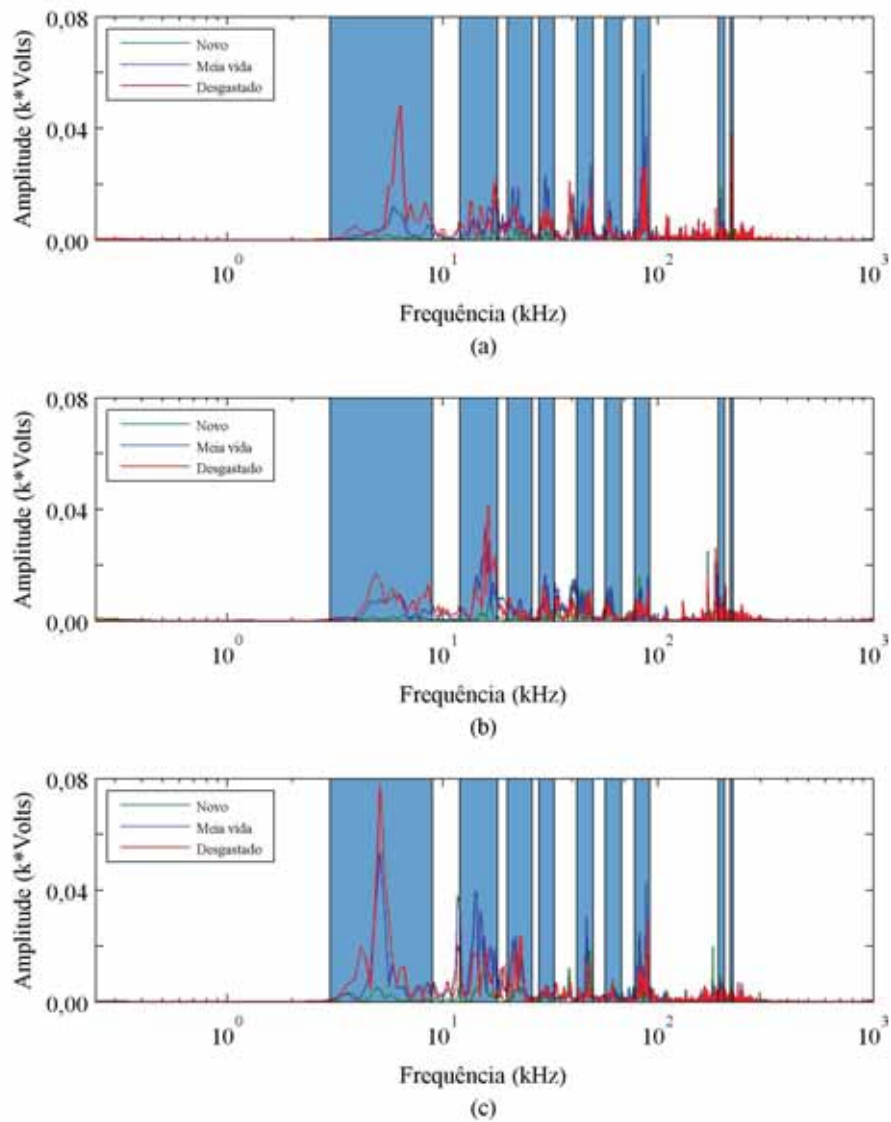


Figura 38 - Espectro de frequência com as bandas destacadas. (a) Dressador CVD; (b) Dressador Mato Grosso; (c) Dressador Brasil Extra.

Assim, o sinal puro de EA foi filtrado para essas bandas e o valor médio calculado para as estatísticas RMS e ROP. O filtro digital utilizado foi um passa-banda do tipo *Butterworth*, ordem 5, implementado no MATLAB. A partir desses valores médios, curvas foram obtidas que representam um determinado nível de desgaste, Figura 39 e Figura 40.

Na Figura 39 são apresentadas as curvas dos valores médios RMS e desvios padrão para as três condições de desgaste, em que se observa para a ferramenta nova, linha verde, que existe uma atividade acústica mais discreta nas primeiras três bandas de frequência se comparada com as atividades acústicas das condições de meia vida e desgastada para essas mesmas bandas. Para as bandas seguintes, as amplitudes possuem maior oscilação, ora se aproximando dos valores da condição de ferramenta de meia vida, ora dos valores da condição de ferramenta desgastada. Por outro lado, em geral, observa-se que, para a ferramenta com meia vida, linha azul, ocorre uma maior atividade acústica dentre as três condições de desgaste. E por fim, para a condição de ferramenta desgastada, linha vermelha, o comportamento da curva para as bandas de frequência foi semelhante ao observado na condição de meia vida, porém, as amplitudes foram menores, além de apresentar grande desvio padrão em determinadas bandas de frequência. Vale mencionar que essas características para as três diferentes condições de desgaste da ferramenta, algumas vezes, se interceptam, e mesmo se invertem, como se pode claramente observar nas curvas dos três tipos de dressadores. Assim, verifica-se a não-linearidade dos valores médios da estatística RMS em função das bandas de frequência estudadas para as diferentes condições de desgaste. No entanto, é possível constatar que para determinadas bandas existe uma distinção significativa, com pequeno desvio padrão, entre as três condições de desgaste, as quais podem ser muito úteis em modelos de classificação do desgaste da ferramenta.

As curvas dos valores médios da estatística ROP, Figura 40, apresentaram características semelhantes às observadas para os valores médios da estatística RMS, mas com dispersão dos dados maior, como pode ser verificado pelos desvios padrão.

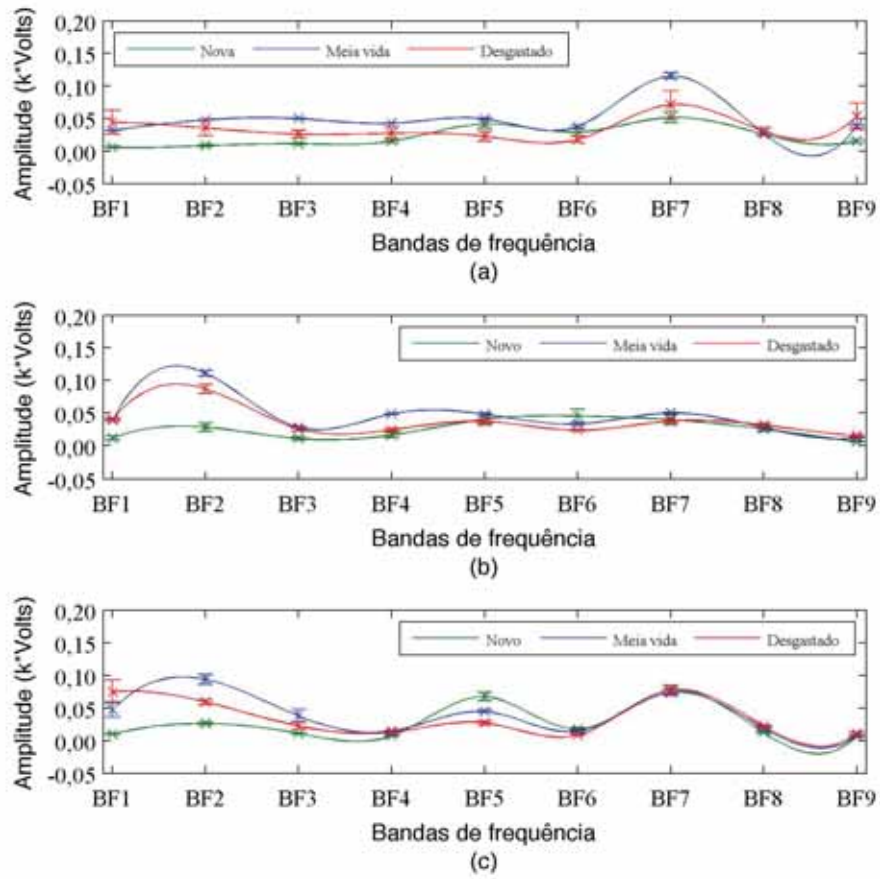


Figura 39 - Valores médios RMS em função das bandas de frequência para os dressadores:
 (a) CVD; (b) Mato Grosso; (c) Brasil Extra.

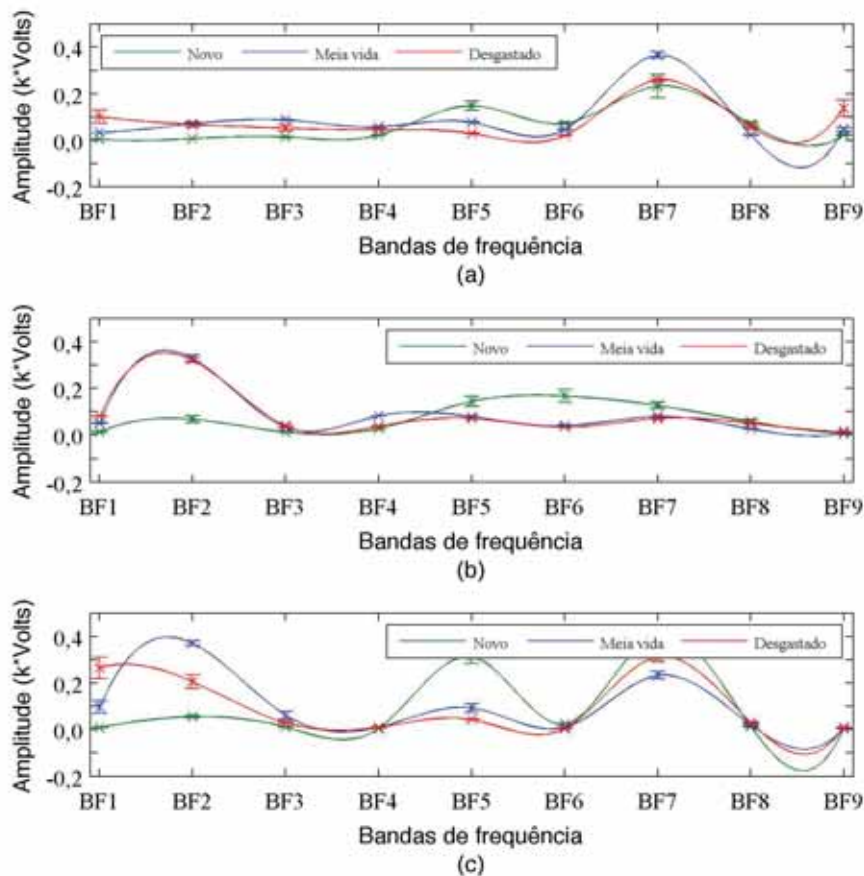


Figura 40 - Valores médio ROP em função das bandas de frequência para os dressadores: (a) CVD; (b) Mato Grosso; (c) Brasil Extra.

4.3 MODELOS NEURAI

Para se obter os melhores modelos neurais foram testadas diferentes combinações de estruturas para a rede. Após organizar os resultados desses testes, selecionaram-se aqueles modelos que apresentaram o menor erro médio e desvio padrão, para as cinco repetições do modelo. Os resultados estão agrupados segundo a quantidade de entradas do modelo neural e o tipo de rede utilizada. Nos grupos de 1 a 3 foi utilizado a rede neural perceptron de múltiplas camadas, enquanto que nos grupos de 4 a 6 foi utilizada a rede neural de Kohonen.

4.3.1 GRUPO 1: REDE NEURAL MLP DE NOVE ENTRADAS

Para os modelos neurais pertencentes a este grupo, os valores médios RMS e ROP das nove bandas de frequência estudadas foram considerados como entradas. As estatísticas RMS

e ROP não foram combinadas nesse grupo. A saída desses modelos consistiu na classificação do diamante em três níveis de desgaste (novo, N; meia vida, MV; desgastado, D). A estrutura geral desse grupo é ilustrada pela Figura 41.

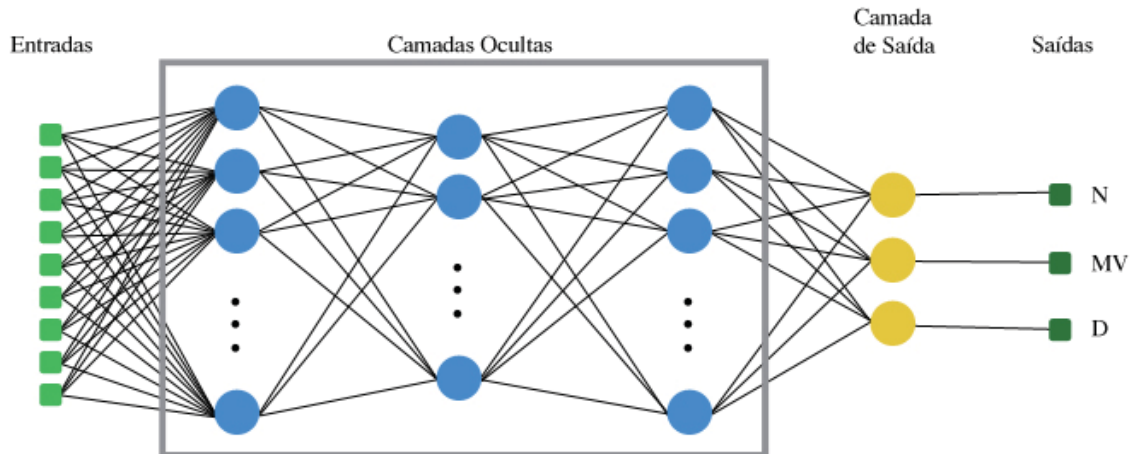


Figura 41 - Estrutura geral dos modelos neurais do Grupo 1.

Na Tabela 27 e na Tabela 28 estão dispostos os melhores modelos neurais obtidos para cada um dos dressadores, para os valores médios RMS e ROP respectivamente. Nessas tabelas estão indicados os erros médios obtidos pelo algoritmo de treinamento e a dispersão deste erro durante as cinco repetições realizadas para cada configuração. Vale salientar que foram consideradas nove entradas de uma dada estatística para esses modelos, referentes a cada banda de frequência.

Tabela 27 - Parâmetros dos modelos neurais do Grupo 1 - RMS.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 1	Modelo 2	Modelo 3
Estrutura	9 - 15 - 3	9 - 5 - 5 - 3	9 - 5 - 3
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>		
Número máximo de épocas	2000		
Erro médio	2,55%	3,15%	1,58%
Desvio padrão	1,17%	1,10%	0,36%

Tabela 28 - Parâmetros dos modelos neurais do Grupo 1 - ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 4	Modelo 5	Modelo 6
Estrutura	9 - 5 - 10 - 3	9 - 10 - 10 - 5 - 3	9 - 10 - 10 - 15 - 3
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>		
Número máximo de épocas	2000		
Erro médio	5,07%	2,38%	7,76%
Desvio padrão	1,90%	1,13%	1,77%

Observa-se que o melhor resultado desses modelos de nove entradas foi o do modelo 3, dressador Brasil Extra, o qual utilizou como entradas a estatística RMS. Apenas para o Dressador Mato Grosso o modelo com entradas da estatística ROP apresentou melhor resultado quando comparado com o modelo cujas entradas foram a estatística RMS. A complexidade dos modelos foi menor para o sinal RMS, exigindo um número menor de camadas ocultas.

Como forma de avaliar os modelos neurais quanto a capacidade de classificação (predição) bem como a sensibilidade (relação entre o número de verdadeiros positivos de uma determinada classe e a quantidade de amostras dessa classe), foram geradas as matrizes de confusão das Figura 42 e Figura 43. Para a construção dessas matrizes de confusão no MATLAB, a última repetição realizada dos cinco treinamentos foi considerada. A matriz de confusão indica na diagonal os acertos de classificação, verdadeiros positivos, para cada classe, enquanto linhas e colunas indicam os erros observados. Nas linhas dessa matriz são apresentados os falsos positivos para uma determinada classe, isto é, quando um dado de outra classe é classificado como pertencente à classe em questão. Já as colunas, indicam a ocorrência de falsos negativos, que acontecem quando dados da classe analisada são classificados em outras classes. A última coluna dessa matriz representa a capacidade de predição do modelo para cada uma das classes, enquanto que, a última linha representa a sensibilidade de cada classe. Para o presente estudo, a situação mais indesejada é a ocorrência de falsos negativos para a condição de desgastado, já que nesta situação uma ferramenta fora das condições de uso seria classificada como dentro dos padrões, podendo comprometer os processos seguintes.

Observa-se na Figura 42 as matrizes de confusão dos modelos 1, 2 e 3. Nota-se que apenas o Modelo 1 apresentou falsos negativos para a classe desgastado, apresentando para essa classe uma sensibilidade de 93,5%. Nos modelos 2 e 3 os erros ocorreram na

classificação de dados na condição de meia vida, que foram considerados pela rede neural como desgastados.

Para os modelos 4, 5 e 6, Figura 43, observa-se a ocorrência de falsos negativos para a condição desgastado nos modelos 4 e 6, e um aumento na quantidade falsos positivos para essa mesma condição. A ocorrência de muitos falsos positivos nessa condição não é muito interessante, pois pode indicar o descarte para uma ferramenta ainda apta à realização da dressagem. Para entrada ROP, o Modelo 5 foi aquele que apresentou o menor erro de classificação, obtendo uma taxa de acerto de 98%.

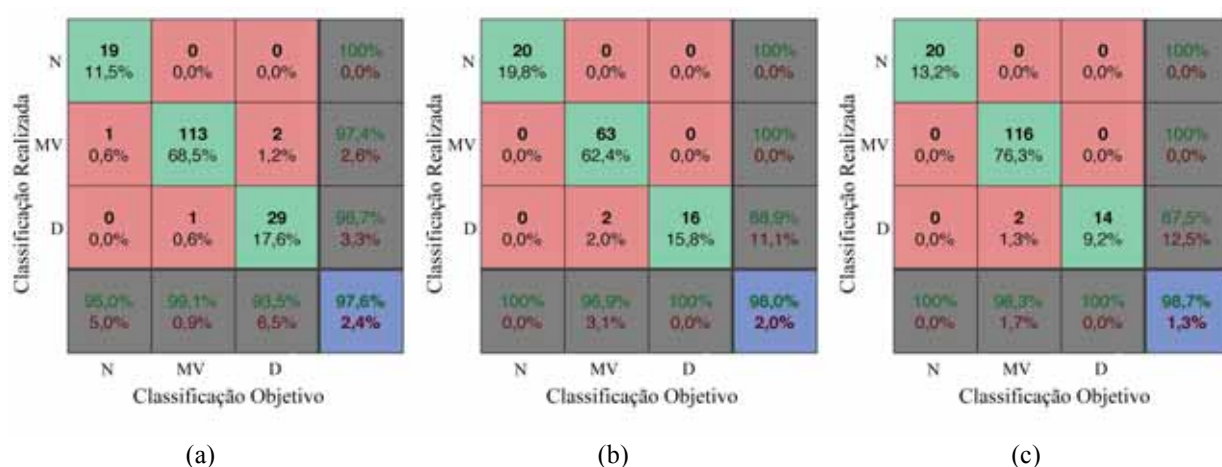


Figura 42 - Matriz de confusão dos modelos: (a) Modelo 1; (b) Modelo 2; (c) Modelo 3.

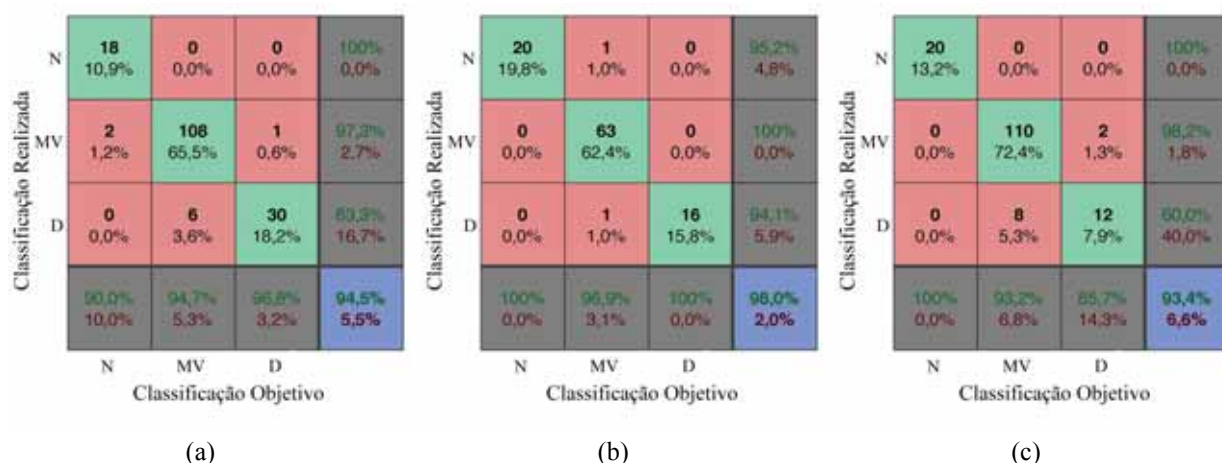


Figura 43 - Matriz de confusão dos modelos: (a) Modelo 4; (b) Modelo 5; (c) Modelo 6.

A classificação desejada e a classificação realizada pelos modelos neurais podem ser vistas em gráficos dos níveis de classificação em função do número de passadas do ensaio, conforme mostram a Figura 44, Figura 45, Figura 46, Figura 47, Figura 48 e Figura 49. Nessas figuras, quando uma passada é corretamente classificada pelo modelo ela é

representada por um ponto azul dentro da região verde. Já quando a classificação é incorreta, a passada é indicada por uma marcação vermelha e dentro da região em que foi classificada pelo modelo. A maioria dos erros foram observados próximos as mudanças da classificação do nível de desgaste dos dressadores.




Figura 44 - Classificação das passadas do ensaio CVD realizada pelo Modelo 1.




Figura 45 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 2.

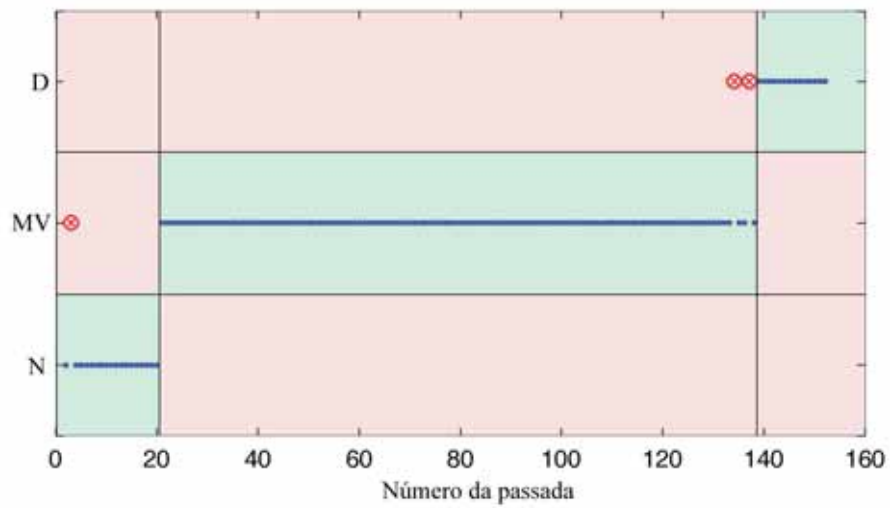


Figura 46 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 3.




Figura 47 - Classificação das passadas do ensaio CVD realizada pelo Modelo 4.




Figura 48 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 5.




Figura 49 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 6.

4.3.2 GRUPO 2: REDE NEURAL MLP DE DUAS ENTRADAS

Com o objetivo de se diminuir o número de entradas dos modelos neurais, foram realizados treinamentos combinando-se duas a duas as bandas de frequência analisadas. Essa análise foi realizada de forma independente para os valores médios RMS e ROP e, após serem selecionadas as duas melhores bandas para cada uma das estatísticas, estas foram utilizadas para obtenção de modelos neurais compostos por uma entrada RMS e outra ROP. A forma geral desses modelos pode ser visualizada na Figura 50.




Figura 50 - Estrutura geral dos modelos neurais do Grupo 2.

Os resultados obtidos após o processamento estão dispostos nas Tabela 29, Tabela 30 e Tabela 31. Observa-se um crescimento do erro médio em relação ao obtido no Grupo 1, e

estruturas neurais mais complexas, sendo necessário um número grande de camadas e neurónios.

Tabela 29 - Parâmetros dos modelos neurais do Grupo 2 - RMS.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 7	Modelo 8	Modelo 9
Estrutura	2 - 5 - 15 - 5 - 3	2 - 5 - 10 - 15 - 3	2 - 5 - 10 - 15 - 3
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>		
Número máximo de épocas	2000		
Bandas de frequência	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	3 - 9 kHz 12 - 18 kHz
Erro médio	2,67%	7,52%	11,97%
Desvio padrão	1,10%	1,13%	1,27%

Tabela 30 - Parâmetros dos modelos neurais do Grupo 2 - ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 10	Modelo 11	Modelo 12
Estrutura	2 - 15 - 20 - 3	2 - 15 - 10 - 5 - 3	2 - 5 - 15 - 3
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>		
Número máximo de épocas	2000		
Bandas de frequência	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	20 - 26 kHz 28 - 33 kHz
Erro médio	2,2%	2,77%	11,45
Desvio padrão	1,23%	0,44%	2,89%

Tabela 31 - Parâmetros dos modelos neurais do Grupo 2 - RMS/ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 13	Modelo 14	Modelo 15
Estrutura	2 - 15 - 20 - 10 - 3	2 - 5 - 15 - 15 - 3	2 - 10 - 10 - 5 - 3
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>		
Número máximo de épocas	2000		
Banda de frequência RMS	42 - 50 kHz	12 - 18 kHz	3 - 9 kHz
Banda de frequência ROP	28 - 33 kHz	3 - 9 kHz	20 - 26 kHz
Erro médio	4,48%	13,66%	9,21%
Desvio padrão	1,40%	1,90%	2,51%

Nota-se quando utilizada apenas duas entradas os valores médios ROP foram os que apresentaram uma melhor caracterização da condição de desgaste da ferramenta. Conforme foi realizado para os modelos do Grupo 1, foram geradas as matrizes de confusão dos

modelos e um gráfico de regiões de classificação. As regiões desse gráfico foram definidas tomando por base a classificação real de cada conjunto de valores de entrada. Em seguida, os dados foram dispostos nesse mapa na forma de pontos, de acordo com a classificação realizada pelo modelo neural. A partir dessa representação, é possível ver no espaço a dispersão dos dados e as regiões de fronteira entre as classes. Essas regiões foram obtidas através de ferramentas estatísticas de extração de características implementadas no MATLAB, de autoria de Franc e Hlavác (FRANC e HLAVÁC, 2004). Observa-se que os erros de classificação estão normalmente situados próximos as bordas das regiões.

A matriz de confusão e as regiões de classificação dos modelos de 7 a 15 estão respectivamente da Figura 51 à Figura 59. Nota-se que nos modelos 8 e 9, apesar do erro elevado, eles se mostraram aptos a identificar a condição desgastada, apresentando apenas um falso negativo para esta condição. Contudo o Modelo 9 não é indicado, pois apresentou um falso negativo entre a classe novo e a classe desgastado, que representa um erro crítico ao sistema. Dentre estes modelos, os mais interessantes foram os modelos 10 e 11; o Modelo 10 por ter apresentado um erro inferior a 2% e o Modelo 11 por ter conseguido distinguir com precisão todas as passadas em que o dressador estava desgastado.

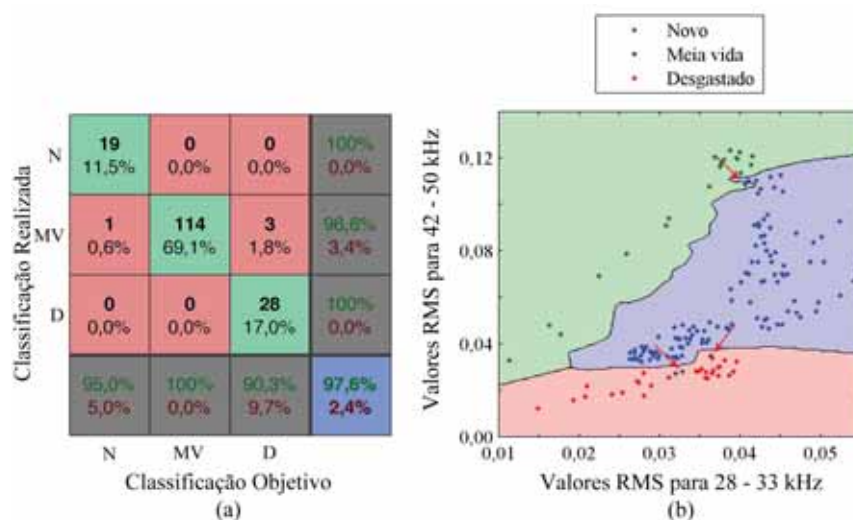


Figura 51 - Resultados do Modelo 7. (a) Matriz de confusão; (b) Regiões de classificação.

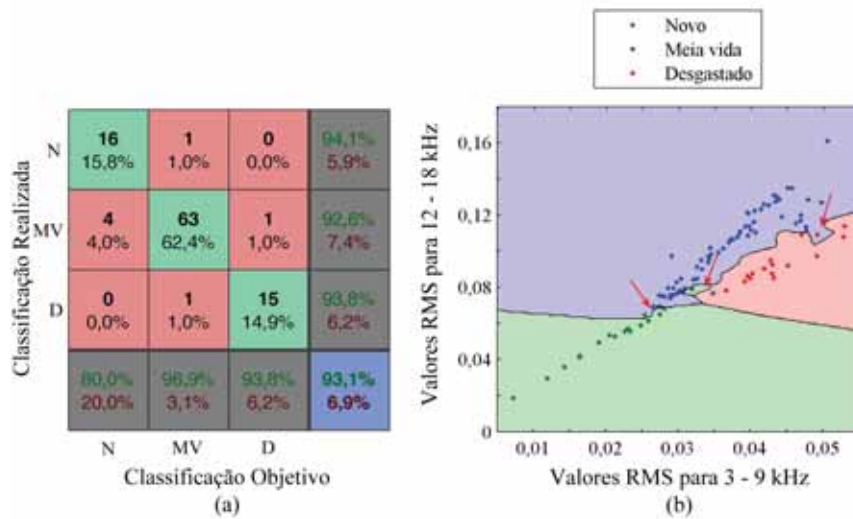


Figura 52 - Resultados do Modelo 8. (a) Matriz de confusão; (b) Regiões de classificação.

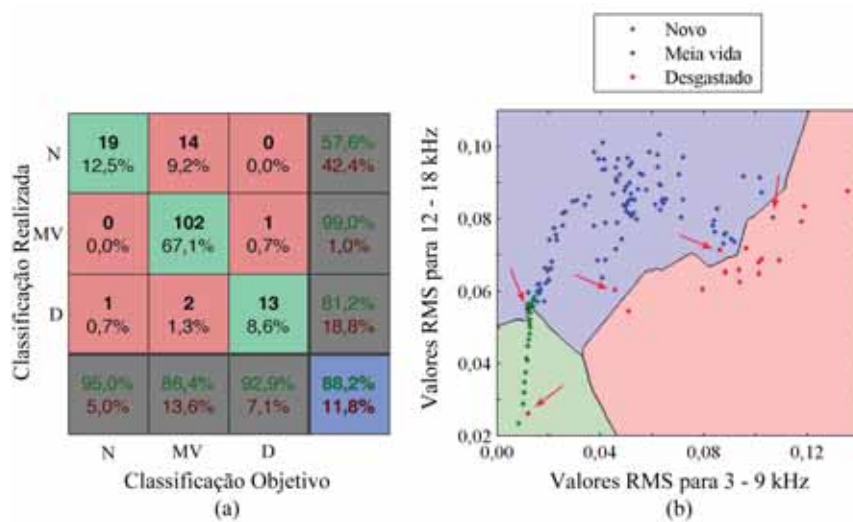


Figura 53 - Resultados do Modelo 9. (a) Matriz de confusão; (b) Regiões de classificação.

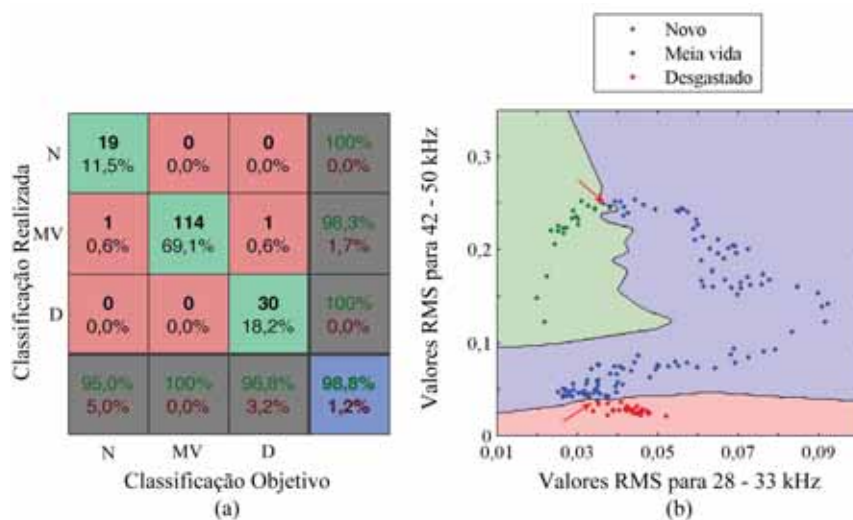


Figura 54 - Resultados do Modelo 10. (a) Matriz de confusão; (b) Regiões de classificação.

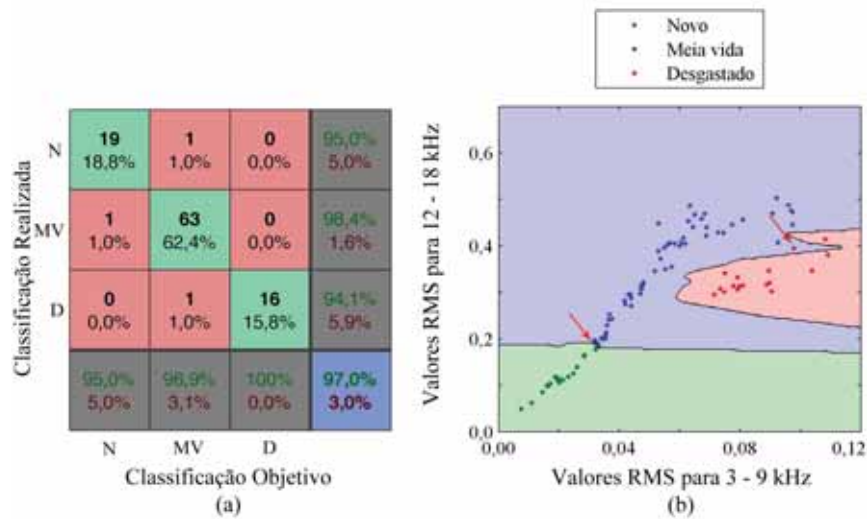


Figura 55 - Resultados do Modelo 11. (a) Matriz de confusão; (b) Regiões de classificação.

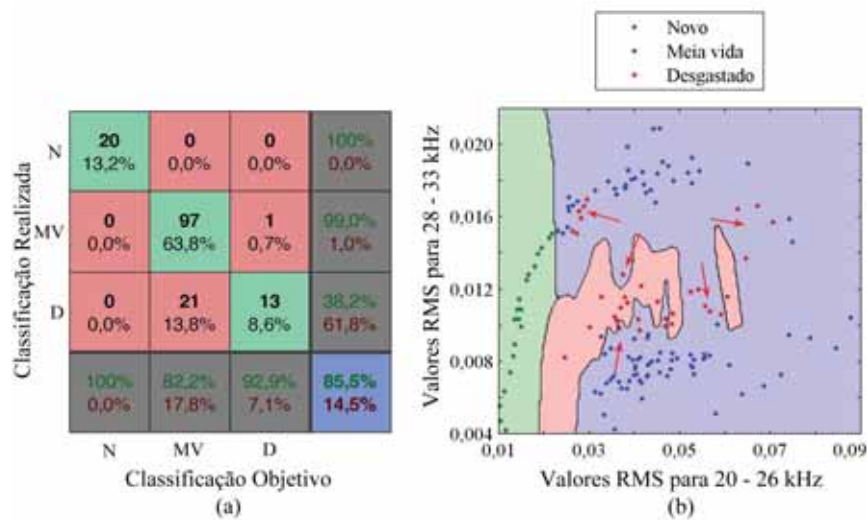


Figura 56 - Resultados do Modelo 12. (a) Matriz de confusão; (b) Regiões de classificação.

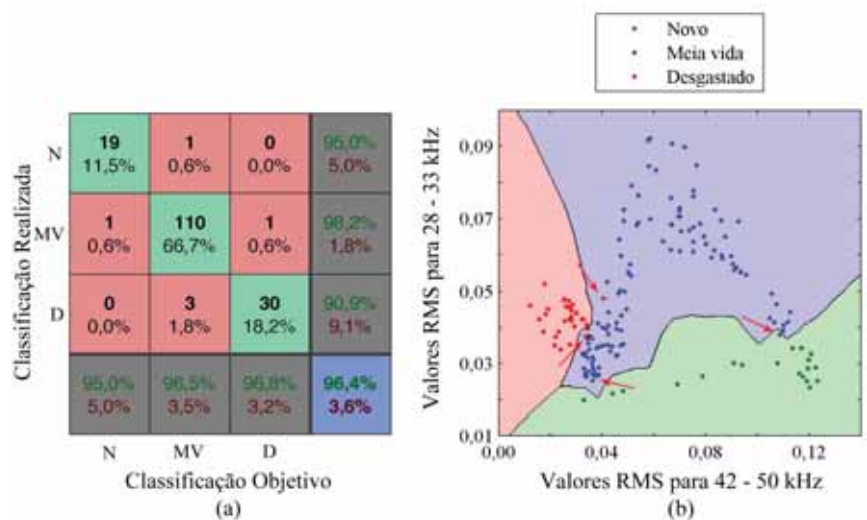


Figura 57 - Resultados do Modelo 13. (a) Matriz de confusão; (b) Regiões de classificação.

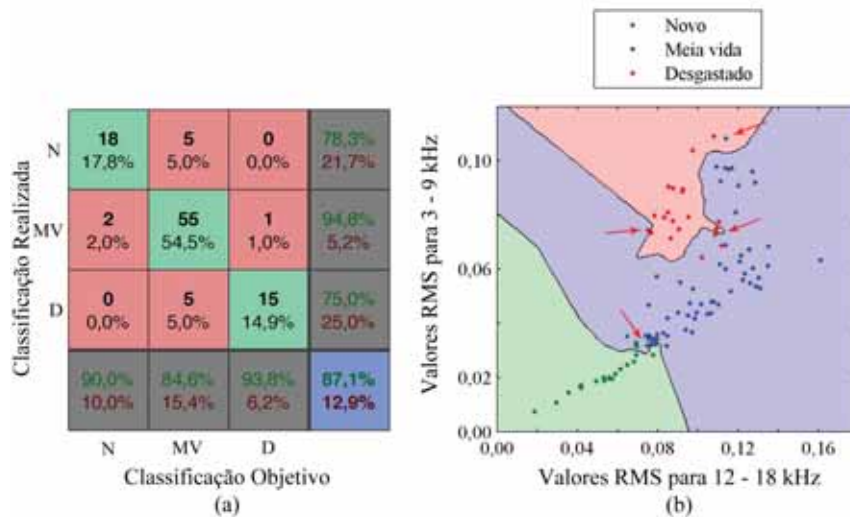


Figura 58 - Resultados do Modelo 14. (a) Matriz de confusão; (b) Regiões de classificação.

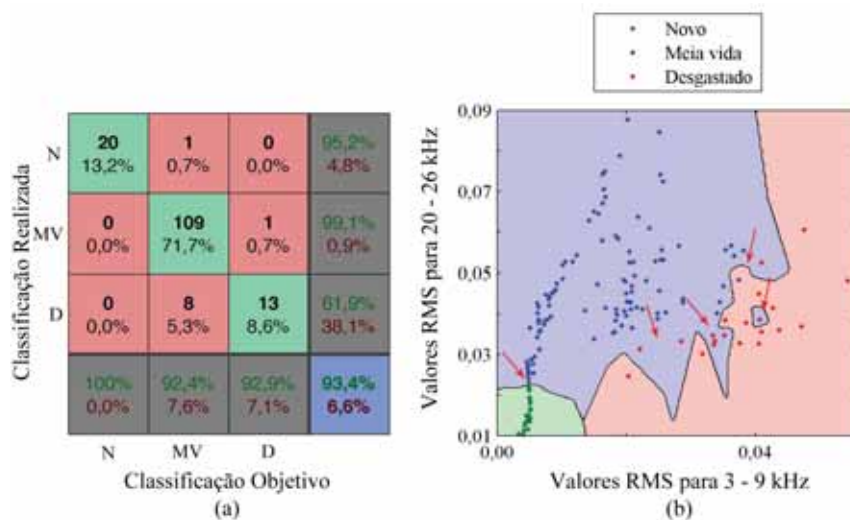


Figura 59 - Resultados do Modelo 15. (a) Matriz de confusão; (b) Regiões de classificação.

Da Figura 60 à Figura 68 são apresentados os resultados da classificação das passadas realizada por cada modelo neural em função do número de passadas do ensaio. A partir dessas figuras, observa-se que para os modelos 10 e 11 as passadas classificadas erroneamente estavam próximas a mudança de classe. Já os demais modelos, não foram capazes de extrair dados suficientes das duas entradas para classificar o nível de desgaste do dressador, os quais apresentaram erros durante varias passadas do ensaio.




Figura 60 - Classificação das passadas do ensaio CVD realizada pelo Modelo 7.




Figura 61 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 8.




Figura 62 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 9.




Figura 63 - Classificação das passadas do ensaio CVD realizada pelo Modelo 10.




Figura 64 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 11.




Figura 65 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 12.




Figura 66 - Classificação das passadas do ensaio CVD realizada pelo Modelo 13.




Figura 67 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 14.




Figura 68 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 15.

4.3.3 GRUPO 3: REDE NEURAL MLP DE QUATRO ENTRADAS

Os modelos neurais desse grupo, cuja estrutura é mostrada na Figura 69, tiveram como entradas as duas melhores bandas de frequência RMS e ROP obtidas no Grupo 2, para cada dressador. A Tabela 32 apresenta os melhores modelos obtidos para esta configuração de entradas.




Figura 69 - Estrutura geral dos modelos neurais do Grupo 3.

Tabela 32 - Parâmetros dos modelos neurais do Grupo 3 - RMS/ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 16	Modelo 17	Modelo 18
Estrutura	4 - 5 - 15 - 15 - 3	4 - 20 - 10 - 20 - 3	4 - 10 - 15 - 10 - 3
Função de treinamento	<i>Levenberg-Marquardt Backpropagation</i>		
Número máximo de épocas	2000		
Banda de frequência RMS	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	3 - 9 kHz 12 - 18 kHz
Banda de frequência ROP	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	20 - 26 kHz 28 - 33 kHz
Erro médio	2,06%	6,34%	2,24%
Desvio padrão	0,54%	3,74%	1,51%

Com o aumento da quantidade de entradas foi possível obter melhores resultados do que os vistos no Grupo 2. Uma exceção fica por conta do Modelo 17, que obteve um erro maior que a melhor configuração do dressador Mato Grosso no Grupo 2. Nota-se que este modelo ainda apresentou um desvio padrão elevado, não demonstrando, portanto, uma boa estabilidade entre os treinamentos.

As Figura 70, Figura 71 e Figura 72 apresentam os resultados obtidos para os modelos 16, 17 e 18 respectivamente. Os três modelos apresentaram cerca de quatro passadas

classificadas erroneamente, sendo o Modelo 16 com o pior cenário, já que ocorreram três falsos negativos para a condição desgastado. O mapa de regiões desse modelo mostra também que os erros de classificação ocorreram longe das fronteiras da região, indicando erros críticos ao processo. Para os modelos 17 e 18 tem-se um nível de acertos maior de classificação em relação ao modelo 16. No entanto, ainda esses modelos apresentam 1 falso negativo na pior condição de desgaste, podendo-se comprometer as especificações de tolerâncias das peças retificadas, embora a porcentagem de que isso ocorra é muito baixa.

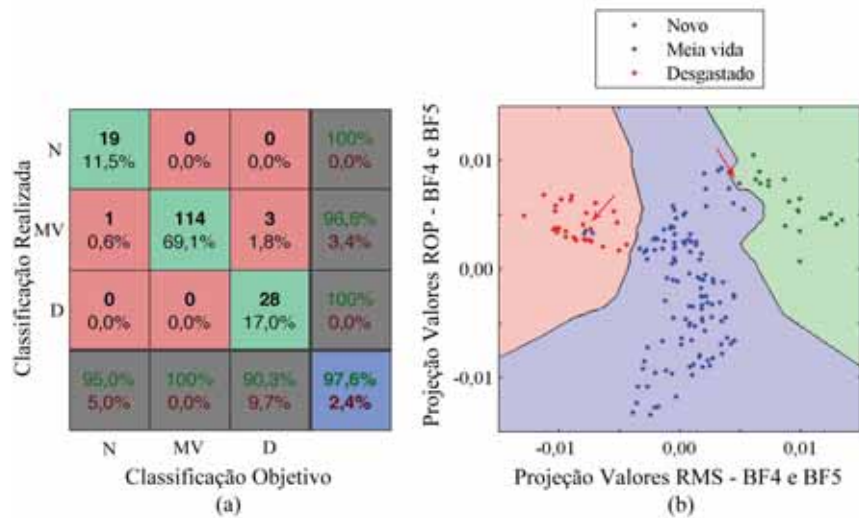


Figura 70 - Resultados do Modelo 16. (a) Matriz de confusão; (b) Regiões de classificação.

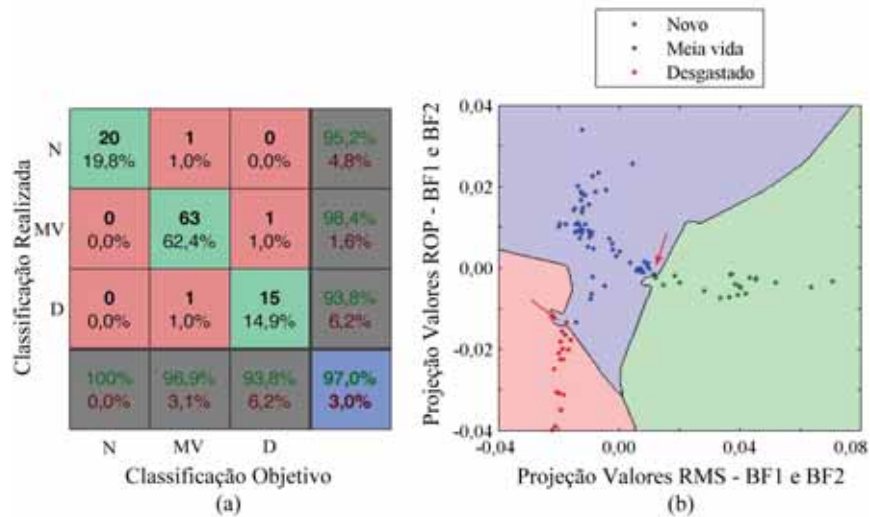


Figura 71 - Resultados do Modelo 17. (a) Matriz de confusão; (b) Regiões de classificação.

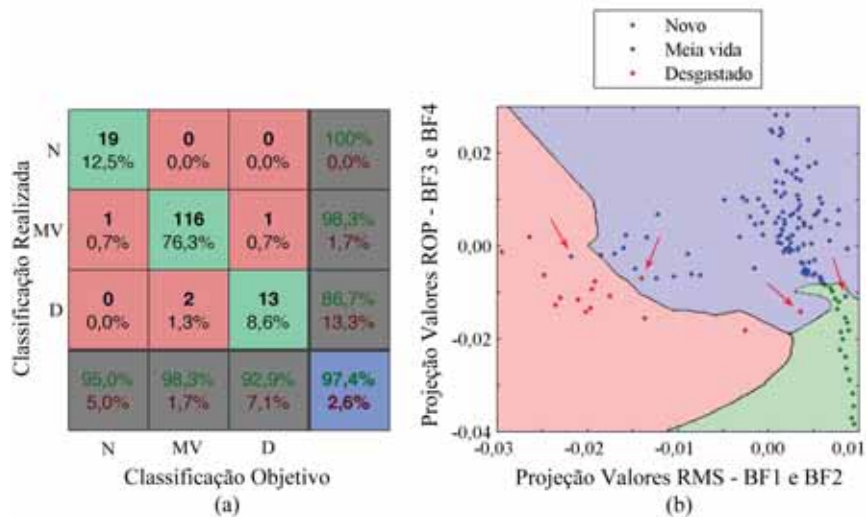


Figura 72 - Resultados do Modelo 18. (a) Matriz de confusão; (b) Regiões de classificação.

A classificação da condição do desgaste do dressador em função do número de passadas pode ser analisada pelos gráficos mostrados na Figura 73, Figura 74 e Figura 75. Observa-se na Figura 73, modelo 16, que o dressador foi classificado incorretamente em quatro passadas da dressagem realizada, sendo três dessas passadas consideradas críticas por estarem distantes da fronteira de classificação. Por outro lado, os modelos 17 e 18, mostrados na Figura 74 e Figura 75, também apresentam classificações incorretas, mas elas ocorrem ou próximas à fronteira de classificação ou em uma classe que não prejudicaria as especificações de tolerâncias de usinagem requeridas. Como exemplo, pode-se citar a condição da ferramenta na passada 64 do modelo 17, em que a classificação correta seria uma ferramenta com meia vida, mas foi classificada como desgastada




Figura 73 - Classificação das passadas do ensaio CVD realizada pelo Modelo 16.




Figura 74 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 17.




Figura 75 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 18.

4.3.4 GRUPO 4: REDE NEURAL DE KOHONEN DE NOVE ENTRADAS

Os modelos neurais gerados nesse grupo foram baseados na rede neural de Kohonen, e tiveram como entradas as nove bandas de frequências estudadas. Os melhores modelos obtidos para essas entradas estão dispostos nas Tabela 33 e Tabela 34, respectivamente para os valores médios RMS e ROP.

Tabela 33 - Parâmetros dos modelos neurais do Grupo 4 - RMS.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 19	Modelo 20	Modelo 21
Dimensões do mapa	14 x 14	15 x 15	10 x 10
Função de treinamento	<i>Batch Weight/Bias Rules</i>		
Número máximo de épocas	1000		
Erro médio	0,61%	1,65%	0,22%
Desvio padrão	0,61%	0,57%	0,38%

Tabela 34 - Parâmetros dos modelos neurais do Grupo 4 - ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 22	Modelo 23	Modelo 24
Dimensões do mapa	10 x 10	8 x 8	14 x 14
Função de treinamento	<i>Batch Weight/Bias Rules</i>		
Número máximo de épocas	1000		
Erro médio	0,61%	0,66%	1,75%
Desvio padrão	0,61%	0,57%	0,38%

Pode-se observar a partir dessas tabelas que ambas as estatísticas apresentaram resultados com baixos erros e desvios padrão. No entanto, o resultado do modelo 23 é bem interessante, pois apresenta a menor dimensão do mapa, indicando uma complexidade menor do modelo bem como um custo computacional mais baixo.

O mesmo procedimento realizado para os outros grupos foi adotado para se avaliar a capacidade de predição e sensibilidade dos modelos, sendo gerada as matrizes de confusão, Figura 76 e Figura 77. Todos os modelos neurais desse grupo apresentaram um índice de classificação muito bom, com a ausência de falsos negativos na pior condição de desgaste. Isto é muito desejável num processo industrial de fabricação. Vale salientar sobre os modelos 19 e 21, os quais apresentaram um índice de 100% de acerto na classificação. Além desses dois modelos, o modelo 23 também merece destaque, pois além de apresentar alto índice de acerto, possui a menor dimensão de mapa (8x8).

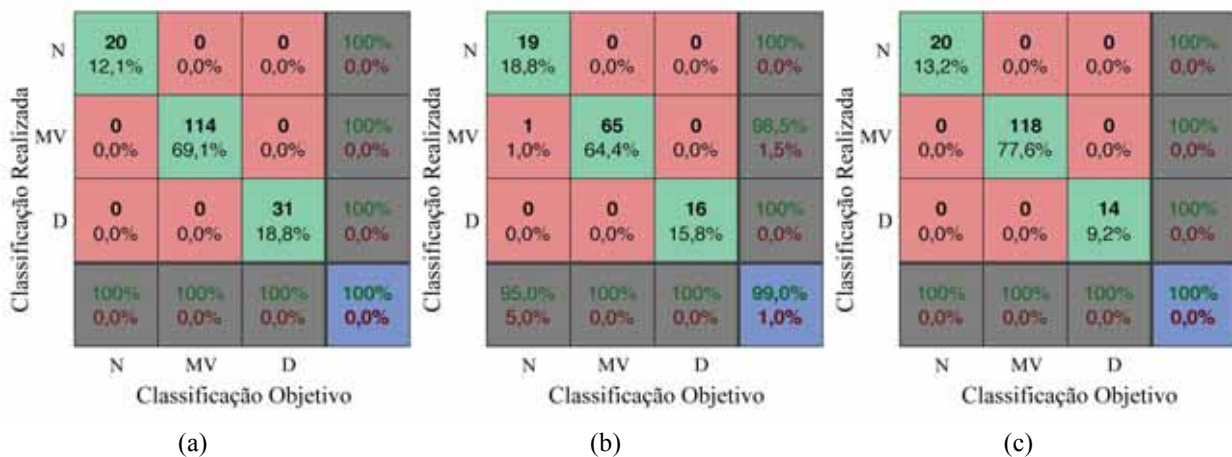


Figura 76 - Matriz de confusão dos modelos: (a) Modelo 19; (b) Modelo 20; (c) Modelo 21.

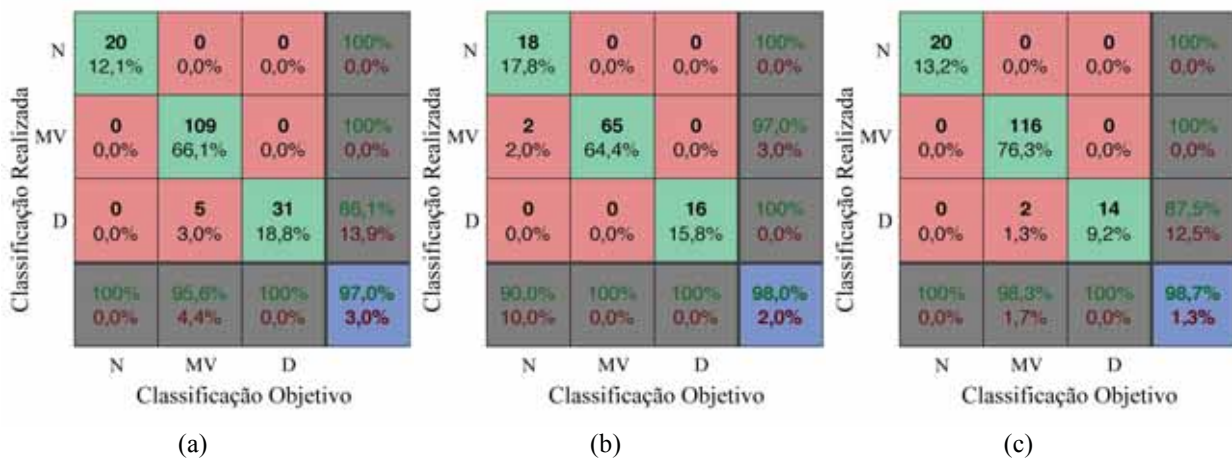


Figura 77 - Matriz de confusão dos modelos: (a) Modelo 22; (b) Modelo 23; (c) Modelo 24.

A classificação do desgaste da ferramenta em função do número de passadas nos ensaios é apresentada da Figura 78 à Figura 83 para os modelos 19 a 24, respectivamente. Observa-se nessas figuras em que passada o dressador foi classificado incorretamente. Como já descrito anteriormente, os modelos, em geral, apresentaram muito bons resultados de classificação, o que também pode ser constatado nesses gráficos. No entanto, para o modelo 23 em que se verificou nas análises anteriores sua menor complexidade (menor dimensão do mapa) e baixo erro de classificação, observa-se na Figura 82 que os erros de classificação ocorreram muito próximos da fronteira, entre a classe de ferramenta nova e de meia vida. Assim, é possível que esses erros, portanto, sejam insignificantes quanto as tolerâncias requeridas na fabricação das peças usinadas. A mesma análise é válida para o modelo 20.

Para os modelos 22 e 24, verifica-se classificações incorretas do desgaste do dressador entre as classes de meia vida e desgastado. Dessa forma, o dressador seria considerado desgastado quando na realidade ele ainda estaria apto para a operação de dressagem. Nesse

caso, o processo se manteria dentro das especificações de acabamento da peça usinada, mas haveria um descarte antecipado do dressador.




Figura 78 - Classificação das passadas do ensaio CVD realizada pelo Modelo 19.




Figura 79 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 20.




Figura 80 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 21.




Figura 81 - Classificação das passadas do ensaio CVD realizada pelo Modelo 22.




Figura 82 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 23.




Figura 83 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 24.

4.3.5 GRUPO 5: REDE NEURAL DE KOHONEN DE DUAS ENTRADAS

Seguindo a mesma estratégia adotada para as redes neurais MLP, no Grupo 2, foram avaliados modelos neurais cujas entradas eram compostas por duas bandas de frequência. Esses testes foram realizados para os valores médios RMS, Tabela 35, valores médios ROP, Tabela 36, e para uma entrada composta por um valor médio RMS e ROP, Tabela 37.

Em comparação com os modelos do Grupo 4, se verifica um aumento significativo do erro médio de classificação para os dressadores com diamantes naturais, Mato Grosso e Brasil Extra, sendo observados erros de até 10,89%. Dentre os modelos desse grupo se destacam o Modelo 25 e o Modelo 28, em especial esse último, pois apresentou um índice de acerto elevado. Para os dressadores Mato Grosso e Brasil Extra, os melhores modelos foram o Modelo 29 e o Modelo 27, respectivamente. No entanto, esses modelos apresentaram uma taxa de erro elevada, de tal forma que essas rede não se tornam confiáveis para a realização da classificação do desgaste.

Tabela 35 - Parâmetros dos modelos neurais do Grupo 5 - RMS.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 25	Modelo 26	Modelo 27
Dimensões do mapa	15 x 15	14 x 14	13 x 13
Função de treinamento	<i>Batch Weight/Bias Rules</i>		
Número máximo de épocas	1000		
Bandas de frequência	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	3 - 9 kHz 12 - 18 kHz
Erro médio	0,61%	10,89%	2,63%
Desvio padrão	0,50%	0,99%	0,50%

Tabela 36 - Parâmetros dos modelos neurais do Grupo 5 - ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 28	Modelo 29	Modelo 30
Dimensões do mapa	12 x 12	15 x 15	14 x 14
Função de treinamento	<i>Batch Weight/Bias Rules</i>		
Número máximo de épocas	1000		
Bandas de frequência	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	20 - 26 kHz 28 - 33 kHz
Erro médio	0,61%	4,95%	8,99%
Desvio padrão	0,50%	0,99%	1,37%

Tabela 37 - Parâmetros dos modelos neurais do Grupo 5 - RMS/ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 31	Modelo 32	Modelo 33
Dimensões do mapa	13 x 13	13 x 13	15 x 15
Função de treinamento	<i>Batch Weight/Bias Rules</i>		
Número máximo de épocas	1000		
Banda de frequência RMS	28 - 33 kHz	3 - 9 kHz	3 - 9 kHz
Banda de frequência ROP	42 - 50 kHz	3 - 9 kHz	20 - 26 kHz
Erro médio	1,41%	5,28%	4,61%
Desvio padrão	0,35%	1,14%	1,32%

Nas Figura 84 à Figura 92 são apresentados os resultados destes modelos na forma de uma matriz de confusão. Observa-se que esses modelos apresentaram uma alta sensibilidade a classificação do nível mais severo de desgaste, com exceção dos modelos 26 e 31 que apresentaram falsos negativos para essa classe. Contudo, as demais classes não obtiveram essa sensibilidade, elevando assim o erro geral do modelo como ocorrido para os modelos 27, 30, 32 e 33. Nota-se que nos modelos 26, 30 e 33 ocorreram erros muito grandes de

classificação, de forma que ferramentas novas foram classificadas como desgastadas e ferramentas desgastadas foram avaliadas como novas. Resultados mais interessantes são observados para os modelos 25, 28 e 29, sendo o Modelo 25 o melhor deles, atingindo um índice de acerto de 100%, enquanto que os outros modelos obtiveram 99,4% e 98%, respectivamente. Para esses modelos, os índices de predição e sensibilidade para a classe de ferramenta desgastada foram de 100%, indicando uma boa capacidade de identificar o momento em que a ferramenta perde as características de trabalho.

Nas regiões de classificação se observa que para a maioria dos modelos desse grupo os erros de classificação do desgaste da ferramenta ocorreram próximos as fronteiras, com exceção dos modelos 26, 30, 32 e 33, que não conseguiram mapear adequadamente as regiões de classificação.

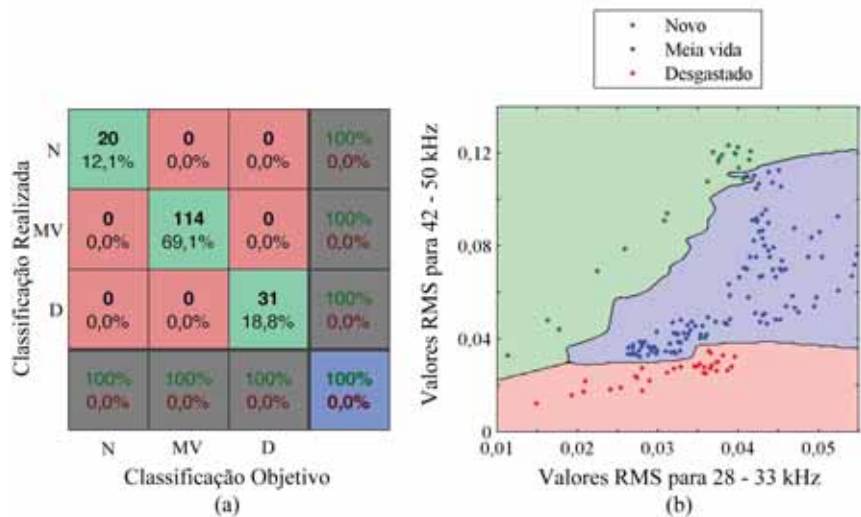


Figura 84 - Resultados do Modelo 25. (a) Matriz de confusão; (b) Regiões de classificação.

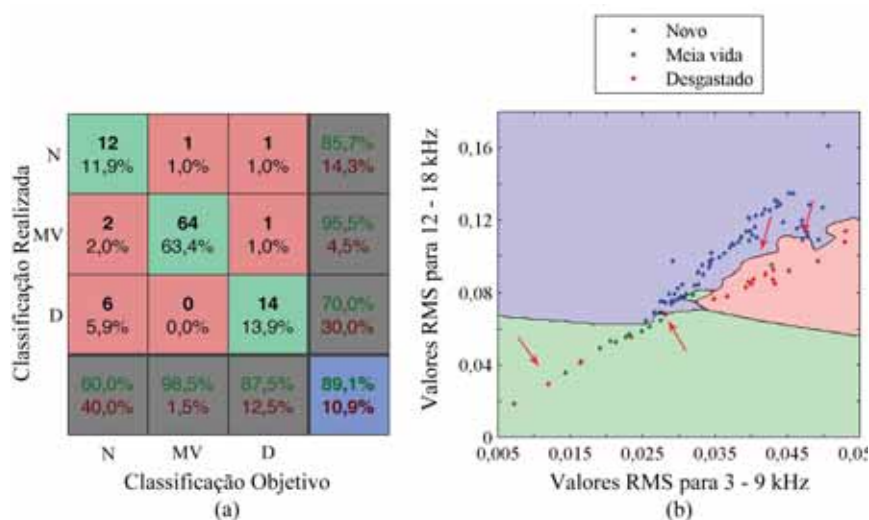


Figura 85 - Resultados do Modelo 26. (a) Matriz de confusão; (b) Regiões de classificação.

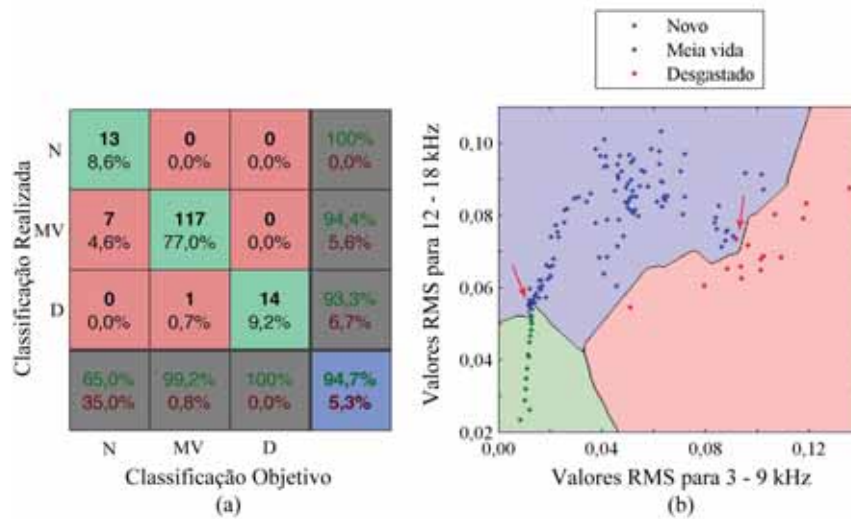


Figura 86 - Resultados do Modelo 27. (a) Matriz de confusão; (b) Regiões de classificação.

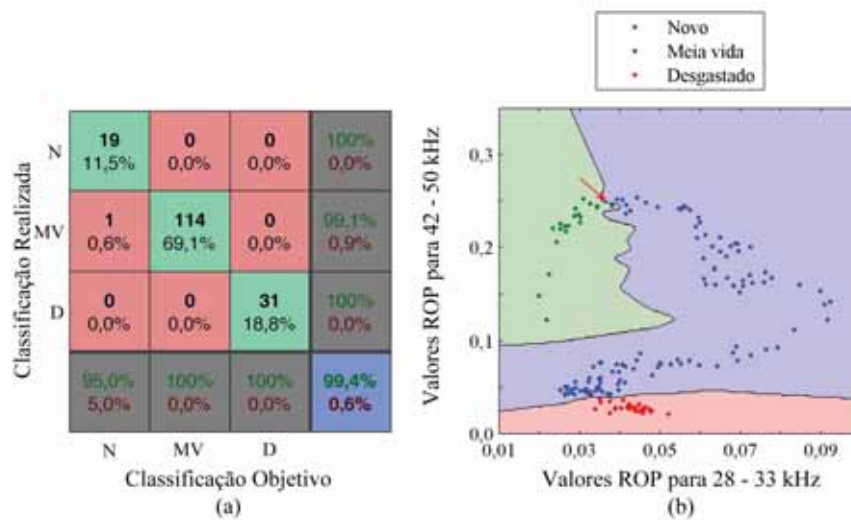


Figura 87 - Resultados do Modelo 28. (a) Matriz de confusão; (b) Regiões de classificação.

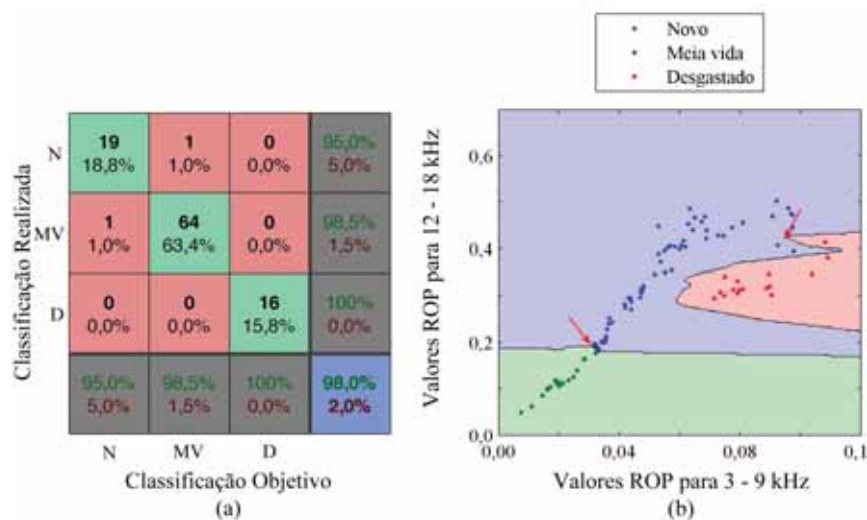


Figura 88 - Resultados do Modelo 29. (a) Matriz de confusão; (b) Regiões de classificação.

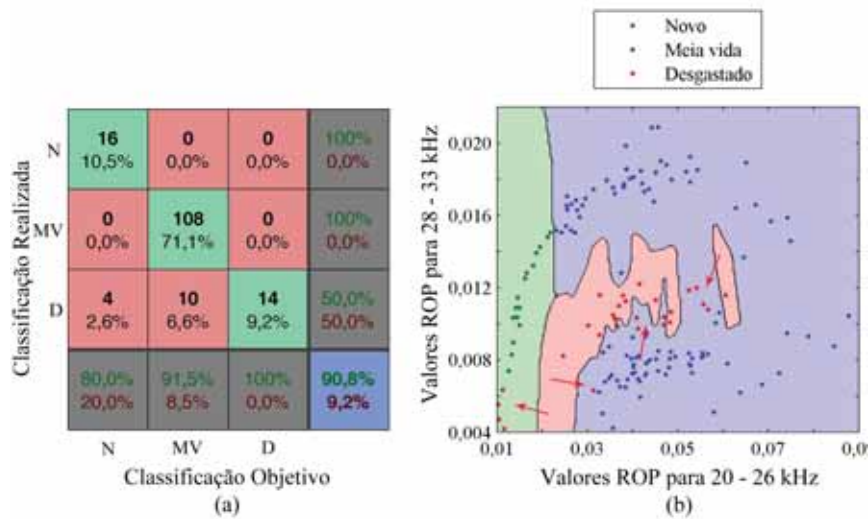


Figura 89 - Resultados do Modelo 30. (a) Matriz de confusão; (b) Regiões de classificação.

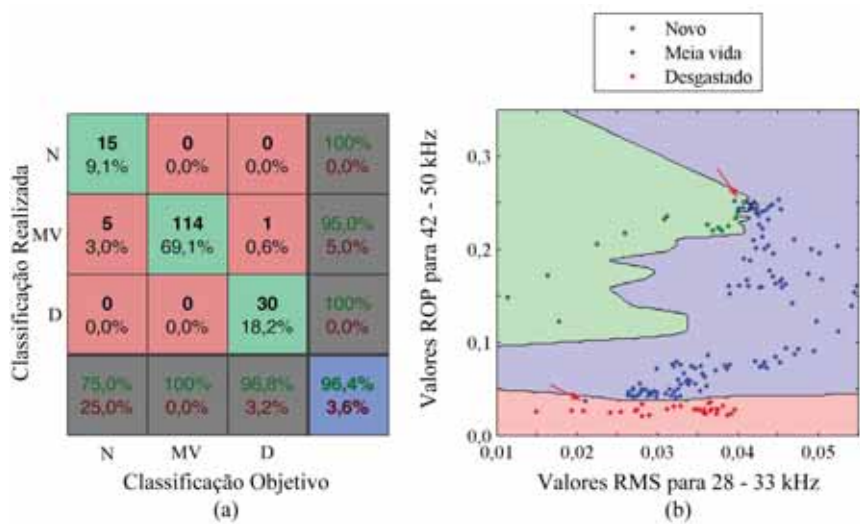


Figura 90 - Resultados do Modelo 31. (a) Matriz de confusão; (b) Regiões de classificação.

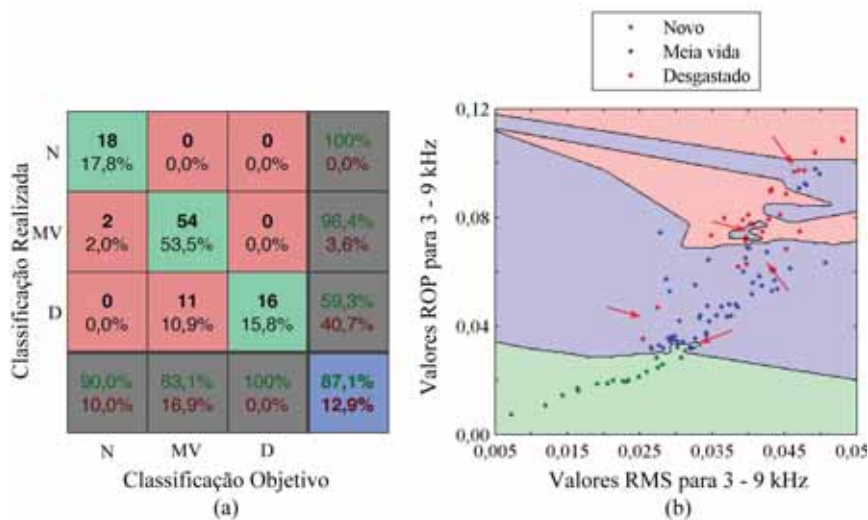


Figura 91 - Resultados do Modelo 32. (a) Matriz de confusão; (b) Regiões de classificação.

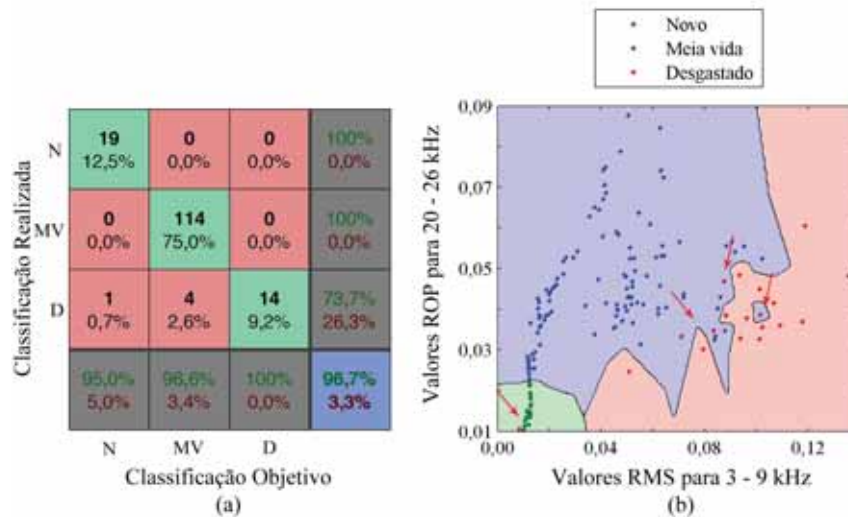


Figura 92 - Resultados do Modelo 33. (a) Matriz de confusão; (b) Regiões de classificação.

A classificação do desgaste do dressador em função do número da passada para os modelos de 25 a 33 estão apresentados da Figura 93 a Figura 101, respectivamente. Nota-se na Figura 94, Figura 98 e Figura 101, modelos 26, 30 e 33, respectivamente, que os falsos positivos para a classe de ferramenta desgastada ocorreram entre dados de classes bem distantes, indicando que as entradas utilizadas para monitorar o processo não foram capazes de caracterizar o desgaste da ferramenta. O modelo 29 apresentou um erro baixo, porém uma passada próxima a condição mais severa de desgaste foi classificada como ferramenta nova, caracterizando um erro grave. Para o modelo 32 se observa erros de classificação para ferramentas com meia vida, porém eles ocorreram em passadas distantes da fronteira de classificação, de modo que ocasionaria no descarte da ferramenta ainda apta para a operação de dressagem. Os modelos 27 e 31 apresentaram erros consideráveis, porém esses erros aconteceram bem próximos a mudança do nível de desgaste, sendo que o erro mais crítico ocorreu no modelo 31, passada 135, pois a ferramenta foi classificada como meia vida quando deveria ter sido classificada como desgastada.




Figura 93 - Classificação das passadas do ensaio CVD realizada pelo Modelo 25.




Figura 94 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 26.




Figura 95 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 27.




Figura 96 - Classificação das passadas do ensaio CVD realizada pelo Modelo 28.




Figura 97 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 29.




Figura 98 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 30.




Figura 99 - Classificação das passadas do ensaio CVD realizada pelo Modelo 31.




Figura 100 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 32.




Figura 101 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 33.

4.3.6 GRUPO 6: REDE NEURAL DE KOHONEN DE QUATRO ENTRADAS

Para esse grupo foram considerados como entradas os valores médios RMS e ROP nas duas bandas selecionados na avaliação do Grupo 5, cujos resultados obtidos para cada tipo de dressador são apresentados na Tabela 38. Observa-se que para esses modelos, com um número maior de entradas que o Grupo 5, foi possível obter um índice pequeno de erros, inferiores a 1%. Destaca-se nesse grupo o Modelo 34, pois apresentou uma taxa média de acerto de 99,8% e com a menor dimensão do mapa neural.

Tabela 38 - Parâmetros dos modelos neurais do Grupo 6 - RMS/ROP.

Parâmetro	Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Nome	Modelo 34	Modelo 35	Modelo 36
Dimensões do mapa	7 x 7	15 x 15	14 x 14
Função de treinamento	<i>Batch Weight/Bias Rules</i>		
Número máximo de épocas	1000		
Banda de frequência RMS	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	3 - 9 kHz 12 - 18 kHz
Banda de frequência ROP	28 - 33 kHz 42 - 50 kHz	3 - 9 kHz 12 - 18 kHz	20 - 26 kHz 28 - 33 kHz
Erro médio	0,20%	0,99%	0,22%
Desvio padrão	0,35%	1,25%	0,38%

A matriz de confusão e as regiões de classificação desses modelos estão apresentados na Figura 102, Figura 103 e Figura 104. Observa-se no modelo 34 a ocorrência de um erro de classificação entre a condição de novo e meia vida para um dado bem próximo a fronteira de classificação. O modelo 35, apesar de possuir um índice de acerto elevado, apresentou um erro grave de classificação, caracterizando como desgastada uma ferramenta nova, cuja passada estava situada muito longe da fronteira de classificação, conforme se pode observar na Figura 103 (b). Para o modelo 36 se alcançou um índice de acerto de 100%.

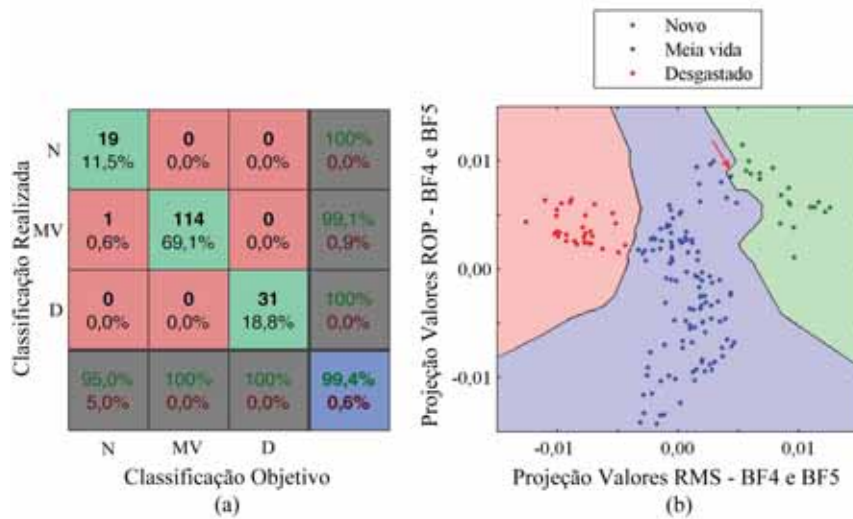


Figura 102 - Resultados do Modelo 34. (a) Matriz de confusão; (b) Regiões de classificação.

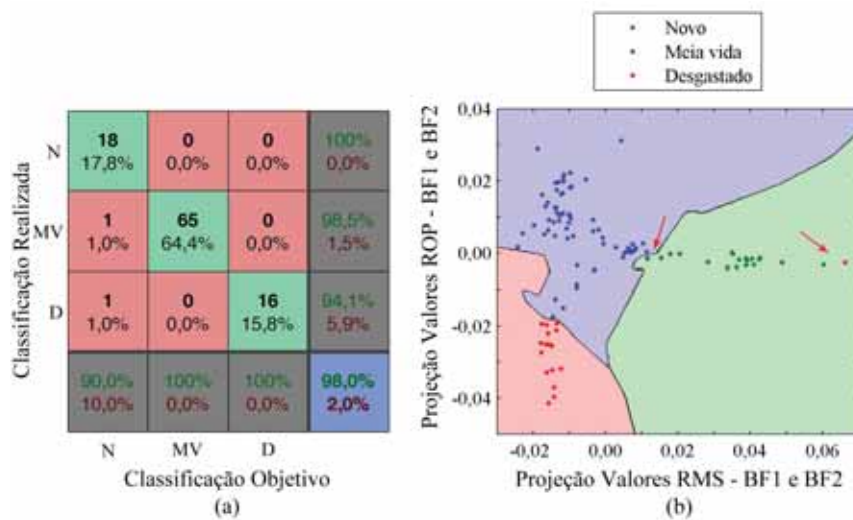


Figura 103 - Resultados do Modelo 35. (a) Matriz de confusão; (b) Regiões de classificação.

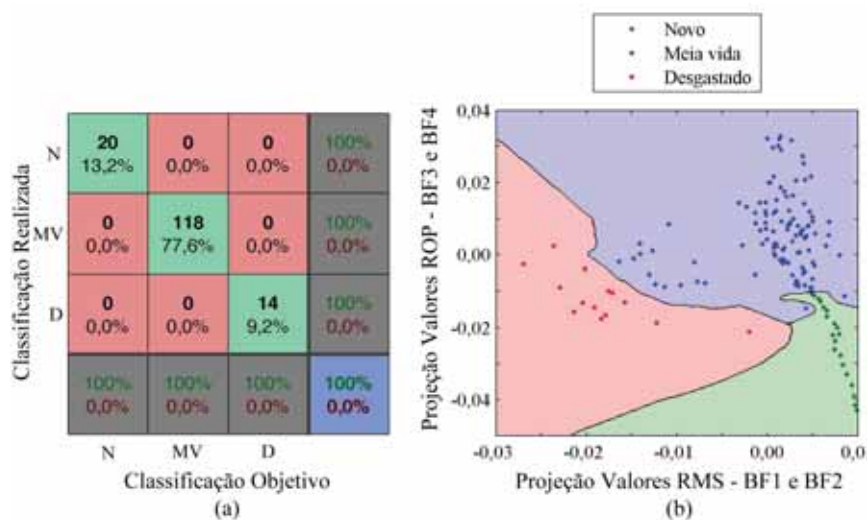


Figura 104 - Resultados do Modelo 36. (a) Matriz de confusão; (b) Regiões de classificação.

Na Figura 105, Figura 106 e Figura 107 é possível observar a classificação do desgaste da ferramenta em função do número da passada do ensaio. Nota-se que o erro de classificação que ocorreu no modelo 34 aconteceu na transição de uma ferramenta nova para meia vida. No entanto, o modelo 35 classificou como desgastada uma ferramenta que era utilizada pela primeira vez.




Figura 105 - Classificação das passadas do ensaio CVD realizada pelo Modelo 34.




Figura 106 - Classificação das passadas do ensaio Mato Grosso realizada pelo Modelo 35.




Figura 107 - Classificação das passadas do ensaio Brasil Extra realizada pelo Modelo 36.

4.3.7 COMPARAÇÃO ENTRE OS MODELOS NEURAIIS

Para permitir uma melhor interpretação dos resultados obtidos, as principais características dos modelos apresentados estão dispostas nas Tabela 39 e Tabela 40 para os modelos neurais MLP e Kohonen, respectivamente.

Observa-se na Tabela 39 que para o dressador CVD o modelo que apresentou o menor erro foi o Modelo 16. Contudo, nele ocorreram três falsos negativos para a condição de desgastado, situação em que o sistema indicaria a ferramenta desgastada como apta a realizar a operação, sendo que estes erros ocorrem longe da fronteira entre as classes. Assim o Modelo 10 se apresenta de forma mais interessante para a classificação do desgaste do dressador CVD, pois nesse modelo apresentou apenas um falso negativo para a classificação de desgastado, e com erro médio de 2,20%.

Para o dressador Mato Grosso os melhores modelos, na ordem crescente de erro, foram o 5, 11 e o 2. Esses modelos foram capazes de identificar com precisão todas as passadas desgastadas e apresentaram um erro médio inferior a 5%. Dentre eles, destaca-se o Modelo 11 que apresentou um erro baixo, 2,77%, não apresentou falsos negativos e utiliza apenas duas entradas, fato esse interessante para um sistema de monitoramento em tempo real.

Observa-se para o dressador Brasil Extra que apenas dois modelos, 3 e 18, apresentaram um resultado satisfatório na classificação do desgaste, sendo que o Modelo 3, de nove entradas, foi o único a não possuir falsos negativos.

Tabela 39 - Valores de erro médio dos modelos neurais MLP.

Entradas		Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Grupo 1 9 entradas	RMS	Modelo 1 Erro: 2,55% Desvio: 1,17 F. N. ¹ : 2 F. P. ² : 1	Modelo 2 Erro: 3,15% Desvio: 1,10 F. N.: 0 F. P.: 2	Modelo 3 Erro: 1,58% Desvio: 0,36 F. N.: 0 F. P.: 2
	ROP	Modelo 4 Erro: 5,07% Desvio: 1,90 F. N.: 1 F. P.: 6	Modelo 5 Erro: 2,38% Desvio: 1,13 F. N.: 0 F. P.: 1	Modelo 6 Erro: 7,76% Desvio: 1,77 F. N.: 2 F. P.: 8
Grupo 2 2 entradas	RMS	Modelo 7 Erro: 2,67% Desvio: 1,10 F. N.: 3 F. P.: 0	Modelo 8 Erro: 7,52% Desvio: 1,13 F. N.: 1 F. P.: 1	Modelo 9 Erro: 11,97% Desvio: 1,27 F. N.: 1 F. P.: 2
	ROP	Modelo 10 Erro: 2,20% Desvio: 1,23 F. N.: 1 F. P.: 0	Modelo 11 Erro: 2,77% Desvio: 0,44 F. N.: 0 F. P.: 1	Modelo 12 Erro: 11,45% Desvio: 2,89 F. N.: 1 F. P.: 21
	RMS ROP	Modelo 13 Erro: 4,48% Desvio: 1,40 F. N.: 1 F. P.: 3	Modelo 14 Erro: 13,66% Desvio: 1,90 F. N.: 1 F. P.: 5	Modelo 15 Erro: 9,21% Desvio: 2,51 F. N.: 1 F. P.: 8
Grupo 3 4 entradas	RMS ROP	Modelo 16 Erro: 2,06% Desvio: 0,54 F. N.: 3 F. P.: 0	Modelo 17 Erro: 6,34% Desvio: 3,74 F. N.: 1 F. P.: 1	Modelo 18 Erro: 2,24% Desvio: 1,51 F. N.: 1 F. P.: 2

¹: F. N. - falsos negativos para a condição de desgastado;

²: F. P. - falsos positivos para a condição de desgastado.

Na Tabela 40 se observa que dentre os modelos neurais de Kohonen para o dressador CVD, apenas o Modelo 31 apresentou um erro superior a 1%, sendo também o único a apresentar a ocorrência de um falso negativo. Destacam-se para esse dressador os modelos 25 e 28, pois utilizando apenas duas entradas foram capazes de apresentar uma taxa média de acerto de 99,40%.

No dressador Mato Grosso os resultados não foram tão expressivos como os observados para o dressador CVD, de tal modo que apenas dois modelos apresentaram um erro médio inferior a 1%. Desses modelos, o melhor foi o Modelo 23, que além de apresentar

o menor erro, não teve falsos negativos e falsos positivos para a classe de ferramenta desgastada.

Para o dressador Brasil Extra, os modelos 21 e 36 foram os melhores, coincidentemente apresentaram os mesmos resultados. Porém, o Modelo 36 é mais interessante, pois utiliza um número menor de entradas, algo bom para um sistema de monitoramento em tempo real.

Tabela 40 - Valores de erro médio dos modelos neurais de Kohonen.

Entradas		Dressador CVD	Dressador Mato Grosso	Dressador Brasil Extra
Grupo 4 9 entradas	RMS	Modelo 19 Erro: 0,61% Desvio: 0,61 F. N. ¹ : 0 F. P. ² : 0	Modelo 20 Erro: 1,65% Desvio: 0,57 F. N.: 0 F. P.: 0	Modelo 21 Erro: 0,22% Desvio: 0,38 F. N.: 0 F. P.: 0
	ROP	Modelo 22 Erro: 0,61% Desvio: 0,61 F. N.: 0 F. P.: 5	Modelo 23 Erro: 0,66% Desvio: 0,57 F. N.: 0 F. P.: 0	Modelo 24 Erro: 1,75% Desvio: 0,38 F. N.: 0 F. P.: 2
Grupo 5 2 entradas	RMS	Modelo 25 Erro: 0,61% Desvio: 0,50 F. N.: 0 F. P.: 0	Modelo 26 Erro: 10,89% Desvio: 0,99 F. N.: 2 F. P.: 6	Modelo 27 Erro: 2,63% Desvio: 0,50 F. N.: 0 F. P.: 1
	ROP	Modelo 28 Erro: 0,61% Desvio: 0,50 F. N.: 0 F. P.: 0	Modelo 29 Erro: 4,95% Desvio: 0,99 F. N.: 0 F. P.: 0	Modelo 30 Erro: 8,99% Desvio: 1,37 F. N.: 0 F. P.: 14
	RMS ROP	Modelo 31 Erro: 1,41% Desvio: 0,35 F. N.: 1 F. P.: 0	Modelo 32 Erro: 5,28% Desvio: 1,14 F. N.: 0 F. P.: 11	Modelo 33 Erro: 4,61% Desvio: 1,32 F. N.: 0 F. P.: 5
Grupo 6 4 entradas	RMS ROP	Modelo 34 Erro: 0,20% Desvio: 0,35 F. N.: 0 F. P.: 0	Modelo 35 Erro: 0,99% Desvio: 1,25 F. N.: 0 F. P.: 1	Modelo 36 Erro: 0,22% Desvio: 0,38 F. N.: 0 F. P.: 0

¹: F. N. - falsos negativos para a condição de desgastado;

²: F. P. - falsos positivos para a condição de desgastado.

De uma maneira geral, os modelos neurais de Kohonen apresentaram uma taxa de acerto mais elevada que os modelos MLP, sendo obtidos modelos com 100% de acerto.

Porém, observou-se um maior número de ocorrências de falsos positivos em alguns desses modelos entre as classes de ferramenta desgastada e ferramenta nova. Nesses modelos a ferramenta nova foi classificada como desgastada bem como a ferramenta desgastada classificada como nova. Esses erros são extremamente indesejáveis em um processo de fabricação, e, portanto, os modelos que apresentaram tais erros devem ser evitados.

Esses erros grosseiros de classificação ocorridos em maior número nos modelos de Kohonen podem ser explicados pelas características de aprendizado da arquitetura de cada rede neural. Enquanto que a rede de Kohonen realiza a classificação a partir de um agrupamento de dados semelhantes, a rede MLP aprende com os padrões de entrada, podendo extrapolar o conhecimento obtido de forma a apresentar menores erros entre classes distantes, como é o caso da classe de ferramenta nova e a classe de ferramenta desgasta.

CAPITULO 5 - CONCLUSÃO

Durante o desenvolvimento do trabalho foi observado uma falta de literaturas que abordassem o tema de monitoramento do desgaste de dressadores. Normalmente, os trabalhos que tratam de dressagem abordam a influência exercida pelos parâmetros de dressagem na rugosidade da peça retificada. De acordo com Wegener *et al.* (2011), a operação de dressagem é extremamente importante para a retificação, e como observado pelos pesquisadores Verkerk (1976), Oliveira *et al.* (2002) e Porzycki (2005), o desgaste do dressador afeta negativamente o resultado da operação de dressagem, comprometendo assim a retificação. A contribuição deste trabalho foi em fornecer um modo eficiente de se identificar níveis de desgaste de um dressador.

O desgaste dos diamantes foi acompanhado realizando-se três ensaios para cada diamante. A área desgastada do diamante comportou-se da forma esperada, apresentando uma característica crescente bem definida, porém devido as diferentes friabilidades dos diamantes, observaram-se variações muito grandes entre as medidas dos ensaios.

Com estudo do sinal puro de EA, em nove bandas de frequência, foi possível determinar comportamentos interessantes da atividade acústica do sinal de acordo com o nível de desgaste. Para algumas bandas de frequência pode-se observar um comportamento crescente, ou um decrescente, da energia do sinal de acordo com o desgaste, enquanto que para outras bandas o comportamento foi mais caótico. A partir dessas bandas foram calculadas as estatísticas RMS e ROP que definiram curvas características para a condição de desgaste do dressador.

Essas curvas foram utilizadas como entradas de 36 modelos neurais, que foram desenvolvidos com o objetivo de realizarem a classificação do desgaste dos dressadores. Esses modelos foram divididos da seguinte maneira: 18 modelos utilizaram redes neurais MLP e outros 18 modelos usaram redes neurais de Kohonen.

Os modelos neurais MLP apresentaram alguns resultados satisfatórios, com uma taxa de acerto superior a 97%. Contudo, alguns dos melhores modelos ainda apresentaram falsos negativos para a condição de ferramenta desgastada. Analisando esses modelos, e objetivando-se um sistema de monitoramento em tempo real, destacam-se os modelos 10 e 11, respectivamente dos dressadores CVD e Mato Grosso, pois neles obteve-se uma taxa de acerto considerável utilizando apenas o valor médio ROP para duas bandas de frequência. Para o dressador Brasil Extra, o modelo com o menor número de entradas e com erro satisfatório foi o Modelo 18, de quatro entradas, porém, para esse modelo foi observado uma

quantidade maior de falsos negativos e falsos positivos para a condição de ferramenta desgastada.

Melhores resultados foram obtidos para os modelos neurais de Kohonen, quando comparados com os modelos MLP, alcançando taxas de acerto de 100% em alguns modelos. Contudo, alguns modelos de Kohonen apresentaram falsos positivos e falsos negativos entre as condições de novo e desgastado, erros estes extremamente indesejáveis, já que no primeiro caso a ferramenta é condenada muito cedo e no segundo caso a operação de dressagem seria comprometida.

Assim, para a tarefa de classificação da condição de desgaste dos dressadores, os modelos mais interessantes foram os de Kohonen, pois apresentaram um erro baixo e utilizando poucas entradas. Caso a proposta dos modelos fosse identificar antecipadamente o momento da troca do dressador, modelos baseados em redes neurais MLP devem apresentar um desempenho superior, por conta das diferentes características dessas redes. Lembrando que redes neurais de Kohonen são indicadas para processo de classificação, enquanto redes neurais MLP são de uso genérico.

5.1 SUGESTÕES PARA OS PRÓXIMOS TRABALHOS

- Utilização de outras ferramentas para o processamento dos sinais, por exemplo, MARSE, CFAR, MVD, wavelets, entre outras;
- Relacionar o sinal de EA com a largura útil do dressador;
- Relacionar o desgaste da ferramenta com a rugosidade obtida em uma peça retificada após a operação de dressagem.

REFERÊNCIAS

- AGUIAR, P. R. et al. Monitoring the dressing operation in the grinding process. **International Journal of Machining and Machinability of Materials**, v. 5, n. 1, p. 3-22, 2009.
- ANGUS, J. C.; HAYMAN, C. C. **Science**, 241, 1988. 913.
- BROOKES, C. A. Diamond in perspective: a review of mechanical properties of natural diamond. **Diamond and related materials**, I, 2010. 13-17.
- CALLISTER, W. D. Estruturas e propriedades das cerâmicas. In: _____ **Ciência e Engenharia de Materiais: Uma Introdução**. 5 ed. ed. [S.l.]: Ed. LTC, 2002. p. 275-300.
- DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da usinagem dos materiais**. 4. ed. Campinas: Artiber Editora Ltda, 2003. 230-248 p.
- DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da usinagem dos materiais**. 7a Edição. ed. Campinas: Artiber Editora Ltda, 2010.
- DURGUMAHANTI, U. S. P.; VIJAYENDER, P. S.; VENKATESWARA, R. A New Model of Grinding Force Prediction and Analysis. **International Journal of Machina Tools & Manufacture**, v. 50, p. 231-240, 2010.
- DYMINSKI, A. S. **Análise de problemas geotécnico através de redes neurais**. PUC - Rio de Janeiro. [S.l.]. 2000.
- EGAÑA, I. et al. Towards Intelligent Dressing. **IEEE Instrumentation & Measurement Magazine**, Junho 2006. 38-43.
- FRANC, V.; HLAVÁČ, V. **Statistical Pattern Recognition Toolbox for Matlab**. Czech Technical University. Prague. 2004. (1213-2365).
- GRAF, W. **Cylindrical Grinding**. [S.l.]: WST Winterthur Schleiftechnik AG, 2004. 87 p.
- HABRAT, W.; BATSCH, J.; PORZYCKI, J. Monitoring of the single-point diamond dresser wear. **ARCHIVES OF CIVIL AND MECHANICAL ENGINEERING**, v. V, n. 1, p. 13-18, 2005.
- HARIMKAR, S. P. et al. Prediction of Solidification Microstructures During Laser Dressing of Alumina Based Grinding Wheel Material. **Journal Physics**, v. 39, p. 1642-1649, 2006.
- HARTMANN, F. R. **Redes Neurais, Conceitos Básicos e Análise**. [S.l.]: Universidade do Vale do Rio dos Sinos - UNISINOS - RS, 2002.

HASSUI, A. et al. Experimental Evaluation on grinding wheel wear through vibration and acoustic emission. **Wear**, 217, 1998. 7-14.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2nd ed. ed. [S.l.]: Pearson Prentice Hall, 1999.

HECKER, R. L.; LIANG, S. Y.; WU, X. J. Grinding force and power modeling based on chip thickness analysis. **International Journal Advanced Manufacture Technology**, v. 33, p. 449-459, 2003.

HEINZEL, C.; RICKENS, K. Engineered wheels for grinding of optical glass. **CIRP Annals**, v. 58, p. 315-318, 2009.

HUANG, S. Artificial neural networks in manufacturing: concepts, applications and perspectives. In: _____ **Manufacturing Technology, Part A**. [S.l.]: [s.n.], v. 17, 1994. p. 212-228.

INASAKI, I.; KARPUSCHEWSKI; WEHMEIRER, M. **Grinding Monitoring System Based on Power and Acoustic Emission Sensors**. Keio University. Yokohama-shi, Japan. 2000.

INASAKI, I.; OKAMURA, K. Monitoring of Dressing and Grinding Processes with Acoustic Emission Signals. **CIRP Annals - Manufacturing Technology**, 34, 1985. 277-280.

JACKSON, M. J. et al. Laser cleaning and dressing of vitrified grinding wheels. **Journal of Materials Processing Technology**, v. 185, p. 17-23, 2007.

KING, R. I.; HAHN, R. S. **Handbook of Modern Grinding Technology**. 3a Ed. ed. New York: Chapman And Hall, 1992.

KOHONEN, T. An introduction to neural computing. In: _____ **Neural networks**. [S.l.]: [s.n.], v. 1, 1988. p. 3-16.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. **Biological Cybernetics**, v. 43, p. 59-69, 1982.

KOIZUMI, S. et al. Appl. Phys. Lett., n. 71, p. 1065, 1997.

KÖNIG, W.; KLOCKE, F. Schleifen, Honen, Läppen, Düsseldorf, 1980.

KWAK, J. S.; HA, M. K. Neural network approach for diagnosis of grinding operation by acoustic emission and power signals. **Journal of Material Processing Technology**, v. 147, n. 1, p. 65-71, 2004.

LEE, D. E. et al. Precision manufacturing process monitoring with acoustic emission. **International of Tools and Manufacture**, 46, 2006. 175-188.

LEE, D. E.; HWANG, I.; DORNFELD, D. A. **Precision Manufacturing Process Monitoring with Acoustic Emission**. University of California. Berkeley. 2004.

LEVENBERG, K. A Method for the Solution of Certain Non-linear Problems in Least Squares. **Quarterly of Applied Mathematics**, v. 2, n. 2, p. 164-168, Julho 1944.

LIANG, S. Y.; HECKER, R. L.; LANDERS, R. G. Machining process monitoring and control: The state-of-the-art. **ASME J. Manuf. Sci. Eng.**, v. 126, n. 2, p. 297-310, 2004.

LIAO, T. W. et al. A wavelet-based methodology for grinding wheel condition monitoring. **International Journal of Machine Tools & Manufacture**, v. 47, p. 580-592, 2007.

LIN, S. Y.; LIU, Y. C.; HUANG, C. W. An investigation of surface grinding characteristics for titanium alloy with CBN wheel. **Key Engineering Materials**, v. 364-366, p. 237-242, 2008.

LINKE, B. Dressing process model for vitrified bonded grinding wheels. **CIRP Annals - Manufacturing Technology**, v. 57, p. 345-348, 2008.

MALKIN, S. **Grinding Technology: theory and applications of machining with abrasives**. 1 ed. ed. Chichester: Ellis Horwood Limited, 1989.

MALKIN, S. **Grinding Technology: Theory and Applications of Machining with Abrasives**. 2 Ed. ed. [S.l.]: Industrial Press, 2008.

MARINESCU, I. D. et al. **Handbook of Machining with Grinding Wheels**. 1a Ed. ed. [S.l.]: CRC Press, 2007.

MARINESCU, I. D. et al. **Tribology of abrasive machining processes**. 1 ed. ed. Norwich: William Andrew Inc., 2004.

MARQUARDT, D. W. An Algorithm for the Least-Squares Estimation of Nonlinear Parameters. **SIAM Journal of Applied Mathematics**, v. 11, n. 2, p. 431-441, Junho 1963.

MORETTIN, L. G. **Estatística Básica - Probabilidade e Inferência: Volume Único**. [S.l.]: MAKRON, 1999.

MUKHERJEE, I.; ROUTROY, S. Comparing the performance of neural networks developed by using Levenberg-Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process. **Expert Systems with Applications**, v. 39, n. 3, p. 2397-2407, 2012.

MUÑOZ, L. A. B. Learning in Feed-Forward Artificial Neural Networks I. In: _____ **Encyclopedia of Artificial Intelligence**. [S.l.]: IGI Global, 2009. p. 1004-1011.

NEGNEVITSKY, M. **Artificial Intelligence: A Guide to Intelligent Systems**. 2nd ed. ed. [S.l.]: Harlow: Addison-Wesley, 2005.

NILSSON, J. W.; RIEDEL, S. A. **Circuitos Eléctricos**. [S.l.]: LTC, 2003.

OLIVEIRA, J. F. G. et al. A New System to Get Information About the Grinding Wheel Performance. **Abrasives Magazine - April/May**, 2000. 24-30.

OLIVEIRA, J. F. G.; BIANCHI, E. C. **Grinding process dominance by means of the dressing operation**. Twenty - Ninth International Matador Conference. [S.l.]: [s.n.]. 1992. p. 547-550.

OLIVEIRA, J. F. G.; SILVA, E. J.; BIFFI, M. New Architecture Control System for an Intelligent High Speed Grinder. **Abrasives Magazine - October/November**, 2002. 1-8.

PORZYCKI, J. Surface-roughness model in traverse grinding. **ARCHIVES OF CIVIL AND MECHANICAL ENGINEERING**, v. V, n. 1, p. 5-12, 2005.

REN, Y. H.; ZHANG, B.; ZHOU, Z. X. Specific energy in grinding of tungsten carbides of various grain sizes. **CIRP Annals - Manufacturing Technology**, v. 58, p. 299-302, 2009.

SALEH, T.; BISHWAS, I.; RAHMAN, M. Efficient dressing of the wheel in ELID grinding by controllable voltage with force feed back. **International Journal of Machine Tools & Manufacture**, 2009.

SALMON, S. C. **Modern Grinding Process Technology**. [S.l.]: MacGraw-Hill, 1992.

SCHÜHLI, L. A. **Monitoramento de operações de retificação usando fusão de sensores**. Universidade de São Paulo. São Carlos. 2007.

STEMMER, C. E. **Ferramentas de Corte II: Brocas, Alargadores, Ferramentas de Roscas, Fresas, Brochas, Rebolos e Abrasivos**. Florianópolis: Editora da UFSC, 1992.

VERKERK, J. **Wheel wear control in grinding. Models for the control of wheel wear, force and surface roughness by choice of dressing and grinding conditions**. TU Delft. [S.l.]. 1976.

WANG, J. Z. et al. **Prediction of surface roughness cylindrical traverse grinding based on ALS algorithm**. Proceedings of the Fourth International Conference on Machine Learning and Cybernetics. Guangzhou: [s.n.]. 2005. p. 549-554.

WEBSTER, J. A. Coolant Calculus: Directing coolant into the right place at the right speed, in the right quantity. **Cutting Tool Technology**, v. 60, n. 2, p. 58-66, 2007.

WEGENER, K. et al. Conditioning and monitoring of grinding wheels. **CIRP Annals - Manufacturing Technology**, v. 60, n. 2, p. 757-777, 2011.

XUE, L.; NAGHDY, F. **Monitoring of wheel dressing operation for precision grinding**. IEEE ICIT'02. [S.l.]: [s.n.]. 2002. p. 1296-1299.

YANG, B. S.; HAN, T.; AN, J. L. ART-KOHONEN neural network for fault diagnosis of rotating machinery. **Mechanical Systems and Signal Processing**, v. 18, n. 3, p. 645-657, 2004.

YANG, J. F.; CHEN, F. K. Recursive discrete Fourier transform with inified IIR filter structures. **Signal Processing**, 82, 2002. 31-41.