

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA
CAMPUS DE BAURU

CARLOS CEZAR DE PAULA SOUZA

**REDES NEURAIIS ARTIFICIAIS APLICADAS NA DETECÇÃO DA
QUEIMA NO PROCESSO DE RETIFICAÇÃO TANGENCIAL PLANA**

Bauru, SP
Janeiro, 2008

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

CARLOS CEZAR DE PAULA SOUZA

**REDES NEURAIS ARTIFICIAIS APLICADAS NA DETECÇÃO DA
QUEIMA NO PROCESSO DE RETIFICAÇÃO TANGENCIAL PLANA**

**Dissertação apresentada à Faculdade
de Engenharia da UNESP – Campus
de Bauru, para a obtenção do título de
Mestre em Engenharia Mecânica.**

Orientador: Prof. Dr. Paulo Roberto de Aguiar
Co-Orientador: Prof. Dr. Eduardo Carlos Bianchi

**Bauru, SP
Janeiro / 2008**

**DIVISÃO TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO
UNESP - BAURU**

Souza, Carlos Cezar de Paula.

Redes neurais artificiais aplicadas na detecção da queima no processo de retificação tangencial plana / Carlos Cezar de Paula Souza, 2008. 128 f. il.

Orientador: Paulo Roberto de Aguiar.

Dissertação (Mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2008.

1. Redes neurais (Computação). 2. Retificação. 3. Redes neurais artificiais. 4. Classificação. 5. Identificação. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título

DEDICATÓRIA

Dedico o presente trabalho à minha esposa Rosania, pela paciência e a Beatriz, minha doce filhinha, por tanto tempo sem poder brincar. A meus pais, que já se foram, de onde tenho a honra de poder tê-los como exemplo.

AGRADECIMENTOS

Agradeço primeiramente e especialmente a Deus por ter me concedido saúde, disposição e capacidade para esta realização.

Agradeço ao meu orientador Prof. Dr. Paulo Roberto de Aguiar, do Departamento de Engenharia Elétrica, da Faculdade de Engenharia, da UNESP de Bauru, pela paciência, confiança e constante auxílio na pesquisa e preocupação com os resultados.

Ao meu Co-Orientador, Prof. Dr. Eduardo Carlos Bianchi, do Departamento de Engenharia Mecânica, da Faculdade de Engenharia, da UNESP de Bauru, por ter repassado tantos conceitos sobre a retificação.

Ao Prof. Dr. Yokio Kobayashi e às secretárias Célia e Yara, do departamento da pós-graduação, que me apoiaram muito.

Agradeço ao Professor Dr. César Antunes de Freitas, da Faculdade de Odontologia da USP de Bauru, do Laboratório de Materiais Dentários que gentilmente cedeu a máquina para os ensaios

Ao pessoal do LADAPS, ao amigo Patrick Nascimento Lançoni, pelas explicações experimentais sobre emissão acústica e RMS.

Aos alunos Marcelo Montepulciano Sapadotto e André Jordan, pela ajuda na confecção das Redes Neurais Artificiais.

Ao pessoal do Laboratório de Usinagem por Abrasão (LUA), por permitir a minha atuação junto a eles, e de forma especial a todos os professores, amigos e funcionários que direta ou indiretamente colaboraram na realização deste trabalho.

À Empresa Bertin, Divisão Alimentos, onde sou Engenheiro da Qualidade, pela confiança depositada em mim, e que muito contribuiu para este mérito, em especial, Evandro Miesse Mente, Diretor Industrial.

SUMÁRIO

DEDICATÓRIA.....	i
AGRADECIMENTOS.....	ii
LISTA DE FIGURAS.....	vi
LISTA DE TABELAS.....	xiv
LISTA DE ABREVIATURAS E SÍMBOLOS.....	xv
RESUMO.....	xvi
ABSTRACT.....	xvii
1 INTRODUÇÃO.....	1
2 OBJETIVO.....	3
2.1 JUSTIFICATIVA.....	3
3 REVISÃO BIBLIOGRÁFICA.....	4
3.1 CARACTERÍSTICAS BÁSICAS.....	4
3.2 A OPERAÇÃO DRESSAGEM.....	5
3.2.1 A dressagem na retificação e sua influência.....	7
3.2.2 Grau de recobrimento (U_d).....	8
3.3 INTEGRIDADE SUPERFICIAL DA PEÇA DE TRABALHO.....	8
3.4 MONITORAMENTO E CONTROLE DO PROCESSO DE RETIFICAÇÃO....	11
3.4.1 Queima e seu Monitoramento no Processo de Retificação Utilizando Sinais de Emissão Acústica e Potência de corte.....	12
3.4.1.1 Parâmetro DPO.....	14
3.4.1.2 Parâmetro DAREA.....	14
3.4.1.3 Parâmetro DIFP.....	15
3.4.1.4 Parâmetro DPKS.....	16
3.5 REDES NEURAIS ARTIFICIAIS – RNA.....	16
3.5.1 O Neurônio Artificial.....	19
3.5.2 Arquitetura da RNA.....	22
3.5.3 Aplicações.....	24
3.5.4 Principais características das Redes Neurais Artificiais.....	25
3.5.5 Treinamentos de Redes Neurais Artificiais.....	26

3.5.6	Tipos de RNA's.....	26
3.5.6.1	Perceptron.....	26
3.5.6.2	Perceptron multicamadas e backpropagation.....	28
3.5.7	Taxa de Aprendizado e Momento.....	30
3.5.8	Validação Cruzada (Cross-Validation).....	31
3.5.9	Redes Neurais Artificiais Aplicadas na Manufatura.....	31
4	MATERIAIS E MÉTODOS.....	34
4.1	EQUIPAMENTOS UTILIZADOS.....	35
4.2	BANCADA DE ENSAIO.....	35
4.3	PREPARAÇÃO E REALIZAÇÃO DOS ENSAIOS.....	37
4.3.1	Preparação dos Corpos de Prova.....	37
4.3.2	Ajuste da Retificadora.....	38
4.3.3	Dressagem.....	40
4.4	MEDIÇÃO DE MICRODUREZA.....	42
5	RESULTADOS E DISCUSSÕES.....	44
5.1	VISUALIZAÇÃO DAS PEÇAS.....	45
5.2	ANÁLISE DE MICRODUREZA.....	50
5.3	RESULTADOS OBTIDOS DO PROCESSAMENTO DOS SINAIS.....	57
5.3.1	Análise dos Parâmetros Estatísticos de Queima.....	68
5.3.1.1	Emissão Acústica – RMS.....	68
5.3.1.2	Potência Elétrica.....	69
5.3.1.3	DPO.....	69
5.3.1.4	DPKS.....	70
5.3.1.5	DIFP.....	71
5.3.1.6	DAREA.....	71
5.3.1.7	Análise dos Degraus.....	72
5.4	REDES NEURAIS ARTIFICIAIS – RNA.....	73
5.4.1	Modelamento das Redes Neurais Artificiais.....	73
5.4.2	Dados de Entrada para Rede Neural Artificial (RNA).....	74
5.4.3	Treinamento das RNA's.....	75
5.4.4	Parâmetros da RNA.....	75
5.4.5	Resultado do treinamento das RNA's.....	76
5.4.6	Resultados das RNA's.....	76
5.4.6.1	RNA 1: EA-RMS, Potência e Profundidade de corte (Estrutura I).....	77

5.4.6.2 RNA 2: DPO e Profundidade de corte (Estrutura II).....	86
5.4.6.3 RNA 3: DPKS e Profundidade de corte (Estrutura III).....	92
5.4.6.4 RNA 4: DAREA e Profundidade de corte (Estrutura IV).....	98
5.4.6.5 RNA 5: DIFP e Profundidade de corte (Estrutura V).....	104
5.4.6.6 Análise de Desempenho das V Estruturas de Redes	
Neurais Artificiais.....	110
5.4.6.7 Erros Médios Absolutos por Estrutura da Classificação.....	111
6 CONCLUSÕES.....	116
7 SUGESTÕES PARA TRABALHOS FUTUROS.....	117
REFERÊNCIAS BIBLIOGRÁFICAS.....	118
ANEXO	
A – RNA DESENVOLVIDA E APLICADA.....	125

LISTA DE FIGURAS

Figura 3.1 – Esquema da superfície de retificação (adaptada de King & Hahn, 1986).....	5
Figura 3.2 – Perfilamento de um rebolo CBN (Dennis & Kaiser, 1999).	6
Figura 3.3 – Dressador de pontas simples e pontas múltiplas (Pricken, 1999).	6
Figura 3.4 – Esquema do processo de dressagem (adaptada de Bianchi, 1990).....	8
Figura 3.5 – Ilustração do algoritmo de extração de passada no sinal de potência (Dotto, 2004).....	15
Figura 3.6 – Neurônio biológico (Haykin, 2001).	18
Figura 3.7 – Neurônio Artificial onde: x é o vetor entrada; w o vetor peso, θk o bias e y_k a saída do neurônio k (Haykin, 2001 - Adaptada).....	20
Figura 3.8 – Diferenças entre um problema linearmente separável e outro não-linearmente separável (Oliveira, 2006).....	28
Figura 3.9 – Esquematização de uma rede Perceptron multicamadas (Haykin, 2001).	29
Figura 3.10 – Fase <i>forward</i> e <i>backward</i> do treinamento de retropropagação (Thomé & Oliveira, 2006).	29
Figura 4.1 – Retificadora cilíndrica de modelo RUAH - 1055, <i>SULMECÂNICA</i>	35
Figura 4.2 – Fixação do sensor de emissão acústica.	36
Figura 4.3 – Diagrama da bancada de ensaios.	37
Figura 4.4 – Corpo de prova tipografado.	38
Figura 4.5 – Corpo de prova em degrau.	38
Figura 4.6 – Ajuste da velocidade tangencial da mesa com tacômetro (Vw).	39
Figura 4.7 – Refratômetro.	39
Figura 4.8 – Operação de dressagem.	40
Figura 4.9 – Dressador posicionado no projetor de perfil.	40
Figura 4.10 – Projetor de perfil usado para medição da largura da ponta do dressador (b_d).	40
Figura 4.11 – Esquema utilizado para medição da largura do ponta do dressador.....	41
Figura 4.12 – Detalhes do equipamento de medição de microdureza.	42
Figura 4.13 – Subdivisões na peça para medir Microdureza.....	43
Figura 5.1 – <i>Software</i> de Quantificação de Queima (Dotto, 2004).	45
Figura 5.2 – Exemplo de Resultados Obtidos do <i>Software</i> de Quantificação de Queima.	45
Figura 5.3 – Gráfico de Quantificação das cores das peças ensaiadas acima de 35 μm	47
Figura 5.4 – Gráfico de Quantificação das cores das peças ensaiadas até 35 μm	48
Figura 5.5 – Média e desvios-padrões da microdureza das peças $a = 10 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça).....	52
Figura 5.6 – Média e desvios-padrões da microdureza das peças $a = 22,5 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça).....	52
Figura 5.7 – Média e desvios-padrões da microdureza das peças $a = 30 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça).....	53
Figura 5.8 – Média e desvios-padrões da microdureza das peças $a = 35 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça).....	53
Figura 5.9 – Média e desvios-padrões da microdureza das peças $a = 40 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça).....	54
Figura 5.10 – Média e desvios-padrões da microdureza das peças $a = 50 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça).....	54

Figura 5.11 – Média de microdureza para cada profundidade de corte e ao longo do comprimento da peça. Eixo horizontal é o número de divisão das medidas ao longo da peça).....	55
Figura 5.12 – Média totais de microdureza das pasadas para cada profundidade de corte e o seu respectivo desvio padrão.....	55
Figura 5.13 – Média e desvios-padrões da microdureza dos degraus (eixo horizontal em número de divisão (secção) ao longo da peça).....	56
Figura 5.14 – Gráficos das Estatísticas para a peça (C1) → 1ª Amostra para $a = 10,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	57
Figura 5.15 – Gráficos das Estatísticas para a peça (C2) → 2ª Amostra para $a = 10,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	58
Figura 5.16 – Gráficos das Estatísticas para a peça (C3) → 3ª Amostra para $a = 10,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	58
Figura 5.17 – Gráficos das Estatísticas para a peça (H1) → 1ª Amostra para $a = 22,5 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	59
Figura 5.18 – Gráficos das Estatísticas para a peça (H2) → 2ª Amostra para $a = 22,5 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	59
Figura 5.19 – Gráficos das Estatísticas para a peça (H3) → 3ª Amostra para $a = 22,5 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	60
Figura 5.20 – Gráficos das Estatísticas para a peça (K1) → 1ª Amostra para $a = 30,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	60
Figura 5.21 – Gráficos das Estatísticas para a peça (K2) → 2ª Amostra para $a = 30,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	61
Figura 5.22 – Gráficos das Estatísticas para a peça (K3) → 3ª Amostra para $a = 30,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	61
Figura 5.23 – Gráficos das Estatísticas para a peça (L1) → 1ª Amostra para $a = 35,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	62
Figura 5.24 – Gráficos das Estatísticas para a peça (L2) → 2ª Amostra para $a = 35,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	62
Figura 5.25 – Gráficos das Estatísticas para a peça (L3) → 3ª Amostra para $a = 35,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	63
Figura 5.26 – Gráficos das Estatísticas para a peça (M1) → 1ª Amostra para $a = 40,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	63
Figura 5.27 – Gráficos das Estatísticas para a peça (M2) → 2ª Amostra para $a = 40,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	64
Figura 5.28 – Gráficos das Estatísticas para a peça (M3) → 3ª Amostra para $a = 40,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	64
Figura 5.29 – Gráficos das Estatísticas para a peça (O1) → 1ª Amostra para $a = 50,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	65
Figura 5.30 – Gráficos das Estatísticas para a peça (O2) → 2ª Amostra para $a = 50,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	65
Figura 5.31 – Gráficos das Estatísticas para a peça (O3) → 3ª Amostra para $a = 50,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em VoltsxK.....	66
Figura 5.32 – Gráficos das Estatísticas para a peça (DG1) – peça com Degrau Escala horizontal em segundos; Escala vertical em VoltsxK.....	66
Figura 5.33 – Gráficos das Estatísticas para a peça (DG2) – peça com Degrau Escala horizontal em segundos; Escala vertical em VoltsxK.....	67

Figura 5.34 – Gráficos das Estatísticas para a peça (DG3) – peça com Degrau Escala horizontal em segundos; Escala vertical em VoltsxK.....	67
Figura 5.35 – Valores médios de EA(RMS) para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	68
Figura 5.36 – Valores médios de Potência Elétrica para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	69
Figura 5.37 – Valores médios de DPO para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	69
Figura 5.38 – Valores médios de DPKS para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	70
Figura 5.39 – Valores médios de DIFP para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	71
Figura 5.40 – Valores médios de DAREA para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	71
Figura 5.41 – Valores médios de EA(RMS) para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	72
Figura 5.42 – Valores médios de Potência Elétrica para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	72
Figura 5.43 – Valores médios de DPO, DPKS, DAREA e DIFP para os ensaios realizados Escala horizontal em μm - profundidade de corte; Escala vertical em VoltsxK.....	73
Figura 5.44 – Estrutura esquemática dos ensaios.....	74
Figura 5.45 – Estruturas de dados de entrada da RNA.....	75
Figura 5.46 – Resultado da RNA (C1) para profundidade de 10,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	77
Figura 5.47 – Resultado da RNA (C2) para profundidade de 10,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	77
Figura 5.48 – Resultado da RNA (C3) para profundidade de 10,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	78
Figura 5.49 – Resultado da RNA (H1) para profundidade de 22,5 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	78
Figura 5.50 – Resultado da RNA (H2) para profundidade de 22,5 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	79
Figura 5.51 – Resultado da RNA (H3) para profundidade de 22,5 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	79
Figura 5.52 – Resultado da RNA (K1) para profundidade de 30,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	80
Figura 5.53 – Resultado da RNA (K2) para profundidade de 30,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	80
Figura 5.54 – Resultado da RNA (K3) para profundidade de 30,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	81

Figura 5.55 – Resultado da RNA (L1) para profundidade de 35,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	81
Figura 5.56 – Resultado da RNA (L2) para profundidade de 35,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	82
Figura 5.57 – Resultado da RNA (L3) para profundidade de 35,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	82
Figura 5.58 – Resultado da RNA (M1) para profundidade de 40,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	83
Figura 5.59 – Resultado da RNA (M2) para profundidade de 40,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	83
Figura 5.60 – Resultado da RNA (M3) para profundidade de 40,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	84
Figura 5.61 – Resultado da RNA (O1) para profundidade de 50,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	84
Figura 5.62 – Resultado da RNA (O2) para profundidade de 50,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	85
Figura 5.63 – Resultado da RNA (O3) para profundidade de 50,0 μm . A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	85
Figura 5.64 – Resultado da RNA (C1) para profundidade de 10,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	86
Figura 5.65 – Resultado da RNA (C2) para profundidade de 10,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	86
Figura 5.66 – Resultado da RNA (C3) para profundidade de 10,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	86
Figura 5.67 – Resultado da RNA (H1) para profundidade de 22,5 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	87
Figura 5.68 – Resultado da RNA (H2) para profundidade de 22,5 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	87
Figura 5.69 – Resultado da RNA (H3) para profundidade de 22,5 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	87
Figura 5.70 – Resultado da RNA (K1) para profundidade de 30,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	88
Figura 5.71 – Resultado da RNA (K2) para profundidade de 30,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	88

Figura 5.72 – Resultado da RNA (K3) para profundidade de 30,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	88
Figura 5.73 – Resultado da RNA (L1) para profundidade de 35,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	89
Figura 5.74 – Resultado da RNA (L2) para profundidade de 35,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	89
Figura 5.75 – Resultado da RNA (L3) para profundidade de 35,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	89
Figura 5.76 – Resultado da RNA (M1) para profundidade de 40,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	90
Figura 5.77 – Resultado da RNA (M2) para profundidade de 40,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	90
Figura 5.78 – Resultado da RNA (M3) para profundidade de 40,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	90
Figura 5.79 – Resultado da RNA (O1) para profundidade de 50,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	91
Figura 5.80 – Resultado da RNA (O2) para profundidade de 50,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	91
Figura 5.81 – Resultado da RNA (O3) para profundidade de 50,0 μm . A) Sinal DPO; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	91
Figura 5.82 – Resultado da RNA (C1) para profundidade de 10,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	92
Figura 5.83 – Resultado da RNA (C2) para profundidade de 10,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	92
Figura 5.84 – Resultado da RNA (C3) para profundidade de 10,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	92
Figura 5.85 – Resultado da RNA (H1) para profundidade de 22,5 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	93
Figura 5.86 – Resultado da RNA (H2) para profundidade de 22,5 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	93
Figura 5.87 – Resultado da RNA (H3) para profundidade de 22,5 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	93
Figura 5.88 – Resultado da RNA (K1) para profundidade de 30,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	94

Figura 5.89 – Resultado da RNA (K2) para profundidade de 30,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	94
Figura 5.90 – Resultado da RNA (K3) para profundidade de 30,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	94
Figura 5.91 – Resultado da RNA (L1) para profundidade de 35,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	95
Figura 5.92 – Resultado da RNA (L2) para profundidade de 35,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	95
Figura 5.93 – Resultado da RNA (L3) para profundidade de 35,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	95
Figura 5.94 – Resultado da RNA (M1) para profundidade de 40,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	96
Figura 5.95 – Resultado da RNA (M2) para profundidade de 40,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	96
Figura 5.96 – Resultado da RNA (M3) para profundidade de 40,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	96
Figura 5.97 – Resultado da RNA (O1) para profundidade de 50,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	97
Figura 5.98 – Resultado da RNA (O2) para profundidade de 50,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	97
Figura 5.99 – Resultado da RNA (O3) para profundidade de 50,0 μm . A) Sinal DPKS; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	97
Figura 5.100 – Resultado da RNA (C1) para profundidade de 10,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	98
Figura 5.101 – Resultado da RNA (C2) para profundidade de 10,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	98
Figura 5.102 – Resultado da RNA (C3) para profundidade de 10,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	98
Figura 5.103 – Resultado da RNA (H1) para profundidade de 22,5 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	99
Figura 5.104 – Resultado da RNA (H2) para profundidade de 22,5 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	99
Figura 5.105 – Resultado da RNA (H3) para profundidade de 22,5 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	99

Figura 5.106 – Resultado da RNA (K1) para profundidade de 30,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	100
Figura 5.107 – Resultado da RNA (K2) para profundidade de 30,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	100
Figura 5.108 – Resultado da RNA (K3) para profundidade de 30,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	100
Figura 5.109 – Resultado da RNA (L1) para profundidade de 35,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	101
Figura 5.110 – Resultado da RNA (L2) para profundidade de 35,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	101
Figura 5.111 – Resultado da RNA (L3) para profundidade de 35,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	101
Figura 5.112 – Resultado da RNA (M1) para profundidade de 40,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	102
Figura 5.113 – Resultado da RNA (M2) para profundidade de 40,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	102
Figura 5.114 – Resultado da RNA (M3) para profundidade de 40,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	102
Figura 5.115 – Resultado da RNA (O1) para profundidade de 50,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	103
Figura 5.116 – Resultado da RNA (O2) para profundidade de 50,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	103
Figura 5.117 – Resultado da RNA (O3) para profundidade de 50,0 μm . A) Sinal DAREA; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	103
Figura 5.118 – Resultado da RNA (C1) para profundidade de 10,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	104
Figura 5.119 – Resultado da RNA (C2) para profundidade de 10,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	104
Figura 5.120 – Resultado da RNA (C3) para profundidade de 10,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	104
Figura 5.121 – Resultado da RNA (H1) para profundidade de 22,5 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	105
Figura 5.122 – Resultado da RNA (H2) para profundidade de 22,5 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	105

Figura 5.123 – Resultado da RNA (H3) para profundidade de 22,5 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	105
Figura 5.124 – Resultado da RNA (K1) para profundidade de 30,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	106
Figura 5.125 – Resultado da RNA (K2) para profundidade de 30,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	106
Figura 5.126 – Resultado da RNA (K3) para profundidade de 30,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	106
Figura 5.127 – Resultado da RNA (L1) para profundidade de 35,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	107
Figura 5.128 – Resultado da RNA (L2) para profundidade de 35,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	107
Figura 5.129 – Resultado da RNA (L3) para profundidade de 35,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	107
Figura 5.130 – Resultado da RNA (M1) para profundidade de 40,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	108
Figura 5.131 – Resultado da RNA (M2) para profundidade de 40,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	108
Figura 5.132 – Resultado da RNA (M3) para profundidade de 40,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	108
Figura 5.133 – Resultado da RNA (O1) para profundidade de 50,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	109
Figura 5.134 – Resultado da RNA (O2) para profundidade de 50,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	109
Figura 5.135 – Resultado da RNA (O3) para profundidade de 50,0 μm . A) Sinal DIFP; B) Imagem da peça usinada Escala horizontal em segundos; Escala vertical em VoltsxK.....	109
Figura 5.136 – Erros Médios Absolutos por Estrutura da Classificação por Peça – 10,0 μm Escala horizontal por número de Estrutura; Escala vertical em unidade.....	111
Figura 5.137 – Erros Médios Absolutos por Estrutura da Classificação por Peça – 22,5 μm Escala horizontal por número de Estrutura; Escala vertical em unidade.....	112
Figura 5.138 – Erros Médios Absolutos por Estrutura da Classificação por Peça – 30,0 μm Escala horizontal por número de Estrutura; Escala vertical em unidade.....	112
Figura 5.139 – Erros Médios Absolutos por Estrutura da Classificação por Peça – 35,0 μm Escala horizontal por número de Estrutura; Escala vertical em unidade.....	113
Figura 5.140 – Erros Médios Absolutos por Estrutura da Classificação por Peça – 40,0 μm Escala horizontal por número de Estrutura; Escala vertical em unidade.....	113
Figura 5.141 – Erros Médios Absolutos por Estrutura da Classificação por Peça – 50,0 μm Escala horizontal por número de Estrutura; Escala vertical em unidade.....	114

LISTA DE TABELAS

Tabela 3.1 – Tipos de funções de ativação e suas representações gráficas (Haykin, 2001).....	21
Tabela 5.1 – Fotografias das peças usinadas na retificadora plana.	44
Tabela 5.2 – Quantificação das Cores das peças ensaiadas.....	46
Tabela 5.3 – Análise do Padrão de Cor.....	49
Tabela 5.4 – Microdureza (g/mm^2) medida nas seções de cada corpo.....	51
Tabela 5.5 – Desempenho das 5 Redes Neurais testadas.....	110
Tabela 5.6 – Classificação da queima (RNA).....	115

LISTA DE ABREVIATURAS E SÍMBOLOS

a : penetração do rebolo	[mm]
a_d : penetração de dressagem	[μm]
Al₂O₃ : óxido de alumínio	
b : largura de retificação	[mm]
b_d : largura de trabalho	[μm]
b_s : largura do rebolo	[μm]
CBN : nitreto cúbico de boro	
CNC : comando numérico computadorizado	
d_s : diâmetro do rebolo	[mm]
DAREA : somatória do sinal de potência elevado pela somatória do sinal de EA normalizado	
DPO : multiplicação entre o desvio-padrão do sinal RMS de emissão acústica e a potência elétrica média por passada do rebolo (ciclo)	
DIFP : seno do ângulo alfa (α) multiplicado pela média da EA multiplicado pela potência máxima vezes 100	
DPKS : desvio padrão da EA multiplicado pela somatória da potência subtraída do seu desvio padrão elevada à quarta potência.	
EA : emissão acústica	[V]
F_t : força tangencial de corte	[N]
F_n : força normal de corte	[N]
k - representação do neurônio	
MLP : <i>perceptron</i> de múltiplas camadas	
n : rotação da peça	[rpm]
Pot : potência mecânica de retificação	[W]
P_{elétrica} : potência elétrica do circuito condicionador de sinais	[W]
QL : queima leve	
QS : queima severa	
Q_w : taxa de remoção volumétrica	[mm ³ /s]
RPM : rotação do rebolo	[rpm]
RNA : rede neural artificial	
RNA's : redes neurais artificiais	
RMS : <i>root mean square</i>	
Sd : passo de dressagem	
Std : desvio-padrão	
sgn : função sinal	
V : tensão de saída do motor de acionamento do rebolo	[V]
V_s : velocidade tangencial do rebolo	[m/s]
V_w : velocidade tangencial da peça	[m/s]
V_{sd} : velocidade de avanço de dressagem	[mm/min]
V_{fd} : velocidade de penetração de dressagem	[mm/min]
w : vetor peso das sinapses	
W_t : ondulação teórica	
x : vetor dos dados de entrada da rede neural artificial	
y_k : saída do neurônio	
Z_s : volume de rebolo gasto	[mm ³]
Z_w : volume de material removido	[mm ³]
α : momento	
η : taxa de aprendizado	
ϕ : função de ativação de um neurônio	
θ_k : <i>bias</i> de um neurônio	

RESUMO

A retificação é um processo de usinagem com alta energia específica, e é usado largamente na fabricação de componentes que requerem tolerâncias apertadas e acabamento fino. Aproximadamente toda energia gasta nesse processo é convertida em calor e concentrada dentro da zona de corte, levando às altas temperaturas na superfície da peça. Altas temperaturas podem causar vários problemas relacionados com a qualidade da peça, tais como tensões residuais de tração e queima superficial, reduzindo a resistência à fadiga ou mesmo inutilizando a peça. Um dos problemas mais críticos na implantação do processo de retificação inteligente é a detecção automática da queima superficial nas peças. Vários sistemas de monitoramento de força de corte ou potência e emissão acústica têm sido avaliados por pesquisadores para controlar a qualidade da retificação. Entretanto, tais técnicas de monitoramento ainda falham em determinadas situações, onde as variações do fenômeno não são completamente captadas pelos sinais empregados. O objetivo deste trabalho é classificar os níveis de queima no processo de retificação utilizando as redes neurais artificiais. A partir dos dados coletados experimentalmente em uma retificadora plana, com rebolo de óxido de alumínio, e aço ABNT 1020, implementou-se V estruturas de redes neurais cujas entradas foram os sinais de emissão acústica (RMS), sinal de potência de corte, profundidade de corte e parâmetros estatísticos derivados dos sinais mencionados. Os resultados mostraram que as estruturas de rede neural empregadas classificaram de forma satisfatória os níveis de queima estudados, com exceção da estrutura V que apresentou grande deficiência na classificação de queima leve e não-queima. No entanto, essa estrutura conseguiu classificar o nível de queima severa. Dentre as estruturas estudadas, aquela com as entradas DPO e profundidade de corte mostrou um nível maior de sucesso. Conclui-se que as redes neurais artificiais são boas ferramentas para classificação dos níveis de queima e fornecem meios para otimizar o processo de retificação.

Palavras-chave: *Retificação; Redes Neurais (Computação); Classificação; Identificação; Queima.*

ABSTRACT

Grinding is a high specific energy finish machining process that is used widely in the manufacture of components requiring fine tolerances and smooth finishes. Virtually all the energy spent in grinding is converted into heat and is concentrated within the grinding zone, thereby leading to high temperature at the work surface. The high temperature can cause several quality-related problems with the workpiece, such as residual tensile stress, surface burns, consequently reducing fatigue life or even turning the workpiece into scrap. One of the most critical problems in the implementation of intelligent grinding process is the automatic detection of burn on the ground parts. Several systems for monitoring the cutting force or power and acoustic emission have been assessed by researchers in order to control the quality of the grinding process. However, such techniques still fail in some situations where the phenomenon variations are not completely captured by the signals employed. The objective of this work is to classify the burn degrees in grinding by using the artificial neural networks. From the experimental data acquired in a surface grinding machine with oxide alumium um grinding wheel, ABNT 1020 steel, five neural network structures have been implemented. Acoustic emission (RMS), cutting power, depth of cut and statistic parameters derived from these signals were used as inputs to the neural networks. The results have shown the neural structures successfully classified the burn degrees studied with the exception of the structure V (DIFP parameter and depth of cut), which has presented great deficiency in the classification of slight burn and no-burn. However, this structure has succeeded in classifying severe burn. Among the studied structures, the one having the DPO parameter and depth of cut as inputs has shown a better percentage of success. It can be concluded the artificial neural networks are useful tools for classifying burn degrees and providing means to optimize the grinding process.

Keywords: *Grinding; Artificial Neural Network; Prediction; Classification; Identification; Burn Detection.*

1 INTRODUÇÃO

Atualmente, a globalização e a competitividade cada vez mais acirradas, faz com que a melhoria da produtividade e da qualidade necessárias nos processos bem como a redução de custos. Sendo assim, a necessidade de se investir em tecnologia para os processos de usinagem. A retificação, usualmente é a última etapa do processo, pois é a fase final, onde se dá o acabamento ao último componente. Segundo Souza (2002), mais empresas estão buscando novas formas de alcançar vantagem competitiva e introduzir novos produtos no mercado mais rapidamente e a um custo menor, utilizando, por exemplo, o ambiente de manufatura virtual. A idéia é que esse novo ambiente proposto aborde todo o processo de desenvolvimento, simulação e fabricação do produto, possibilitando a execução dessas atividades no computador, ou seja, virtualmente, antes de realizá-las no mundo real, independentemente do grau de complexidade da forma e da estrutura de um produto.

Segundo Aguiar (2003), um dos problemas mais críticos na implantação do processo de retificação inteligente é a detecção automática de queima superficial nas peças. Isso talvez tenha origem na errônea crença de que o processo é muito complexo para se compreender, devido à multiplicidade de arestas cortantes e sua geometria irregular, altas velocidades de corte, e pequenas profundidades de corte que variam de grão para grão. Segundo Aguiar (1997), a remoção do cavaco no processo de usinagem por abrasão não acontece da mesma maneira que nas operações mais convencionais como fresamento e torneamento. Nessas operações a ferramenta possui geometria de corte definida, enquanto que na retificação a ferramenta apresenta várias arestas cortantes, ou seja, geometria de corte indefinida.

Há muitas variáveis no processo de retificação. A mudança constante da geometria da ferramenta de corte dificulta os resultados esperados, tornando assim, um custo alto, pois danos à peça podem ocorrer a qualquer momento nesse estágio. A necessidade de se buscar processos mais controláveis nessa fase, principalmente as reduções de custos, aliadas ao aumento de qualidade das peças, requer uma junção com sistemas mais inteligentes para os ambientes industriais. Tendo nessa fase um controle dos danos causados no processo de retificação é de interesse direto de todas as indústrias dependentes desse processo, obter uma taxa mais baixa de perdas de peças e conseqüentemente um custo mais baixo de produção. Segundo Malkin (1989), as altas temperaturas geradas na zona de retificação podem causar vários tipos de danos térmicos à peça, como por exemplo, queima (no caso de aços), têmpera excessiva da camada superficial com possível reendurecimento e aumento da fragilidade, indesejáveis tensões residuais de tração, redução da resistência à fadiga e trincas. Para atenuar

a restrição de danos térmicos, é geralmente necessário reduzir a potência de retificação. Isso pode ser obtido utilizando um rebolo mais macio ou uma dressagem mais grosseira; ambas têm suas desvantagens.

Segundo Aguiar (1997) a dificuldade fundamental de controlar os danos causados no processo de retificação é a falta de um método confiável em fornecer realimentação em tempo real durante o processo. Sinais de emissão acústica e potência de corte combinados têm sido utilizados com sucesso na determinação de parâmetros indicativos da queima. Estes sinais tratados e combinados possibilitam a implementação de um sistema de controle em tempo real da queima, otimizando o processo de retificação, o qual seria de grande benefício para as empresas dependentes desse processo, uma vez que a exigência de qualidade e competitividade internacional cresce cada vez mais com a globalização.

A fim de monitorar a queima, observam-se resultados interessantes nos trabalhos realizados por Aguiar et al. (1999), Dotto et al. (2002), Aguiar et al. (2002), e Aguiar (2003), nos quais foram utilizados parâmetros advindos do sinal puro de emissão acústica e o sinal de potência combinados.

O interesse crescente na rede neural artificial pode ser visto como um fenômeno notável a partir de 1980, caracterizado pela sua grande capacidade de processamento e de flexibilidade na integração com outras ferramentas da matemática (AGUIAR et al., 2005). Segundo Aguiar et al. (2005), o uso de redes neurais na detecção da queima no processo de retificação é uma boa alternativa devido a sua capacidade de alto ajuste para novas calibrações, generalizando assim os resultados que podem ser obtidos. Estudos anteriores comprovaram a eficácia desta ferramenta na retificação para se prever a queima superficial de peças (NATHAN, 1999).

O desenvolvimento de um sistema inteligente para a detecção da queima é ainda um desafio para os pesquisadores. Assim, este trabalho visa investigar a queima no processo de retificação a partir de parâmetros obtidos do processamento digital do sinal de emissão acústica, valor médio quadrático (Root Mean Square - RMS) e do sinal de potência de corte, os quais serão as entradas de uma rede neural artificial. Os parâmetros a serem obtidos e utilizados neste trabalho são aqueles em que Aguiar (2003) e Dotto (2004) mostraram ser eficientes na detecção da queima no processo de retificação.

2 OBJETIVO

Esse trabalho tem por objetivo a aplicação de um sistema inteligente para detecção da queima no processo de retificação tangencial plana por meio da utilização de uma rede neural perceptron de múltiplas camadas, treinada para generalizar o processo e, conseqüentemente, efetuar a classificação da queima.

2.1 JUSTIFICATIVA

A procura da otimização do processo de retificação plana por ser a última etapa do processo visando redução de custos e a melhora de sua produtividade bem como sua aplicabilidade das RNA para identificação e classificação da queima.

3 REVISÃO BIBLIOGRÁFICA

Segundo Malkin (1989), o processo de retificação é considerado um dos mais importantes na manufatura, pois quase todos os produtos industrializados possuem componentes que foram concebidos a partir desse processo ou a partir de máquinas que possuem a sua precisão graças à retificação. Trata-se de um processo de alta precisão e importância, já que é inaceitável perder uma peça nessa etapa, pois o valor agregado ao material nessa fase já é muito elevado devido aos outros processos anteriores.

Ainda de acordo com este autor, a queima superficial da peça influencia na alteração da microestrutura do material retificado. Evidências metalúrgicas e medições de microdureza indicam que o limite para início da queima visível coincide com o valor limite da temperatura para início da austenitização do material.

King & Hahn (1986), em operações de planejamento da retificação é necessário definir as entradas e saídas do processo e desenvolver relação entre elas. Para que isso seja feito é importante distinguir as variáveis de entrada na retificadora e entradas do processo de retificação que ocorrem na interação reboło-peça. Os parâmetros de entrada típicos das máquinas retificadoras são: taxa de avanço, velocidade do reboło e da peça, profundidade de dressagem e tempo de centelhamento (*sparkout*).

3.1 CARACTERÍSTICAS BÁSICAS

De acordo com King & Hahn (1986) na retificação existem duas forças: F_n , força normal à superfície de contato reboło-peça e F_t , força tangencial à superfície de contato. Multiplicando F_t pela velocidade do reboło tem-se a potência usada na retificação (quando uma constante apropriada relacionando força e velocidade em potência é usada). Dessa forma taxas volumétricas de remoção por unidade de largura seriam escritas como: F'_n , F'_t , Z'_w , Z'_s (ou Q'_w e Q'_s). Essas convenções são um tanto confusas no início, porém uma vez compreendidas, pode-se ler artigos do mundo inteiro sem a necessidade de checagem contínua dos símbolos. A figura 1 mostra uma configuração da retificação plana que ilustra o cálculo de taxas de remoção volumétricas (Z). A profundidade de corte é denominada pela letra “a”, que é a deflexão entre o reboło e a peça, pois, quando aumenta a área de contato, o número de grãos em contato com a peça aumenta; e a largura do contato denominado por “b”; V_w a velocidade da peça, que coincidente com a velocidade da mesa da máquina retificadora (BIANCHI, 1996).

A taxa de remoção é dada por: $Z = a V_w b$ (Eq. 1)

e a taxa de remoção por unidade de largura é: $Z' = a V_w$ (Eq. 2)

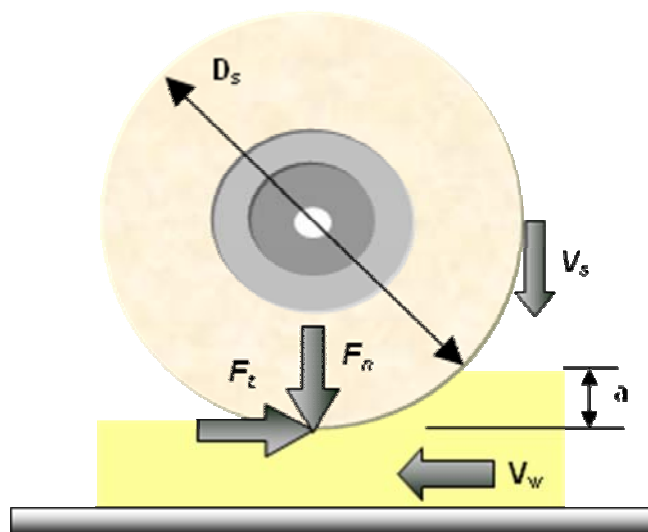


Figura 3.1 – Esquema da superfície de retificação (adaptada de King & Hahn, 1986)

A velocidade de corte V_s exerce uma substancial influência sobre o comportamento das forças de corte, desgaste do rebolo, acabamento e queima superficial da peça, vibrações da máquina, entre outros. Aumentando-se a velocidade de corte pelo aumento da rotação do rebolo, há um aumento da potência de corte consumida, já que a potência de corte é diretamente proporcional à rotação do eixo árvore (Bianchi et al., 1996).

3.2 A OPERAÇÃO DRESSAGEM

A operação dressagem é realizada após a fabricação e uso do rebolo, pois as ferramentas para retificação não se encontram em condições normais para nova utilização. É imprescindível identificar e assegurar as boas condições operacionais do rebolo, sendo duas operações:

- Perfilamento “truing”: caracteriza-se como a operação de dar forma a um rebolo, para fazê-lo girar corretamente centrado, sem batimentos e dar aos bordos do mesmo, um perfil especial capaz de reproduzir corretamente a forma desejada (Stemmer, 1992; Felipe Júnior, 1996). A Figura 2 apresenta o perfilamento de um rebolo de CBN utilizando-se do método de discos diamantados.



Figura 3.2 – Perfilamento de um rebolo CBN (Dennis & Kaiser, 1999).

- Dressagem “dressing” é uma “afiação” ou avivamento dos grãos abrasivos, que consiste em remover, ou fraturar grãos desgastados e “cegos” (rebolo espelhado) ou limpará rebolos “carregados” de cavacos (rebolo empastado). Destina-se também à remoção do ligante para melhorar a exposição dos grãos abrasivos (Krar et al., 1990; Stemmer, 1992; Felipe Júnior, 1996). Também são utilizados diversos tipos de ferramentas denominadas dressadores ou retificadores que incluem: cortadores metálicos (rosetas), bastões retificadores, rodas retificadoras, pontas simples e múltiplas de diamante, conforme ilustrado na Figura 3.




Figura 3.3 – Dressador de ponta simples e pontas múltiplas (Pricken, 1999)

Cada tipo apresenta vantagens específicas. As principais finalidades da operação de dressagem são (AGUIAR, 1997):

- obtenção de concentricidade da face de trabalho com o eixo de rotação;
- perfilamento da face de trabalho para uma operação de forma;
- arrancamento dos grãos abrasivos gastos para melhorar a agressividade da face de trabalho.

Segundo Hassui (2002), a definição do momento correto de dressagem do rebolo é fundamental no processo de retificação. Isso pode ser feito de maneira conservadora, ou seja, antes do fim da vida do rebolo. Dessa forma, ocorrerá um desperdício de abrasivo e

principalmente, um aumento do tempo de processo, pelo maior número de dressagens realizadas. Vale lembrar que o tempo de corte na retificação normalmente é bastante curto em função dos baixos volumes de material removido. Por outro lado, uma utilização do rebolo além da sua vida poderá acarretar uma rejeição da peça retificada. Caso isso ocorra, o custo aumentará significativamente, já que as peças quando chegam nesse estágio possuem alto valor agregado. Nas indústrias a decisão do momento de dressagem é feita, em geral, por operadores da máquina, baseados na variação do ruído gerado pelo processo (HASSUI, 2002).

3.2.1 A Dressagem na retificação e sua influência

Ainda é pouco conhecida em sua totalidade a influência das condições de dressagem na retificação, pois a geometria do dressador é um fator de grande influência que freqüentemente não é levado em conta. A maioria dos trabalhos encontrados na bibliografia utiliza como variáveis do processo a profundidade de dressagem (a_d), largura de trabalho (b_d), largura do rebolo (b_s) e o passo de dressagem (S_d). Segundo Bianchi (1990), são dois os efeitos resultantes da operação de dressagem: o macroefeito e o microefeito. O macroefeito é formado em função do formato do dressador, da profundidade de penetração desse e do passo de dressagem em que é realizada a operação. Esse fenômeno determina a posição na qual as arestas dos grãos abrasivos estão localizadas. Pode-se dizer que o macroefeito é a rosca (ondulação teórica, W_t) que o dressador produz na face do rebolo. A Figura 4 representa o esquema do processo de dressagem. O microefeito é formado pelo arrancamento dos grãos desgastados (com baixa ancoragem na liga) e fratura dos grãos que não se desgastaram por completo, onde novas arestas de corte são geradas pelo dressador. A agressividade das arestas depende das condições de dressagem e da friabilidade (capacidade em formar novas arestas de corte quando fraturado) do grão abrasivo. O fenômeno do microefeito está portanto relacionado com o tipo de aresta que é formada nos grãos abrasivos durante a operação de dressagem, podendo tornar o rebolo mais agressivo ou não.




Figura 3.4 – Esquema do processo de dressagem (adaptado de Bianchi, 1990)

3.2.2 Grau de Recobrimento (U_d)

Segundo König apud Aguiar (1997), a forma de afiação que usualmente é utilizada, ou seja, ajustando-se o avanço do dressador em função do seu tipo, é inadequada, pois não leva em conta a largura de atuação deste no instante da operação. Tal largura varia ainda devido ao desgaste da ponta do dressador durante várias operações de dressagem.

König (1980) definiu o parâmetro denominado por grau de recobrimento (U_d) como sendo a relação entre a largura de atuação do dressador (b_d) e o passo de dressagem (S_d), conforme a Equação 3:

$$U_d = b_d / S_d \quad (\text{Eq. 3})$$

As condições de dressagem influenciam diretamente na taxa de remoção de material que por sua vez interfere na rugosidade superficial da peça produzida.

3.3 INTEGRIDADE SUPERFICIAL DA PEÇA DE TRABALHO

Danos superficiais causados nas peças durante a operação de retificação podem ser causados por efeito térmico, mecânico ou químico. Os tipos de danos térmicos em aços resultantes da temperatura excessiva são: transformação metalúrgica (sobre-têmpera e reendurecimento), micro-trincas, alterações de dureza, tensão residual e deformação, enquanto que impactos mecânicos podem resultar em esforços indesejáveis, deformação plástica e tensão residual de compressão (Kim, 1997).

Um dos tipos mais comuns de danos térmicos no processo de retificação é a queima da peça. Quando a queima superficial da peça se inicia, existe uma tendência do crescimento da adesão de partículas metálicas nos grãos abrasivos do rebolo, tendo como consequência o aumento das forças de retificação. Este aumento de forças provoca a deterioração da qualidade superficial da peça, podendo levar ao aumento da perda diametral do rebolo, fazendo com que seu desgaste volumétrico aumente.

Segundo Malkin (1989), a queima superficial da peça influencia na alteração da microestrutura do material retificado. Através da realização de medições de microdureza na superfície de aços temperados verificou-se que a queima superficial induzida pelo processo de retificação é acompanhada por um processo de reaustenitização do material. Para aços temperados retificados sem queima superficial, existe geralmente um amolecimento do material próximo à superfície, por terem sido atingidas temperaturas inferiores às de austenitização. Com a queima superficial ocorre a retêmpera do material, a qual é consequência da reaustenitização do mesmo, seguida da formação de martensita não revenida. Essa pode ser constatada através da análise metalográfica, resultando no aumento da microdureza superficial. Evidências metalúrgicas e medições de microdureza indicam que o limite para início da queima visível coincide com o valor limite da temperatura para início da austenitização do material (MALKIN, 1989).

Segundo Malkin (1989), a queima superficial da peça, observada para aços de rolamentos, traz um aspecto adverso quanto ao limite de resistência à fadiga e consequente diminuição do número de ciclos desses aços após a retificação. Este comportamento é atribuído à formação de martensita não-revenida, gerada no processo de queima superficial, em função do aquecimento à temperatura de austenitização e resfriamento rápido sem posterior alívio de tensões (revenimento). Existe outra frente de pesquisas que defende o fenômeno do “*film-boiling*” como causa do aumento da temperatura na zona de usinagem. Segundo Howes apud Aguiar (1997), o fenômeno denominado *film-boiling* ocorre durante a retificação, em uma determinada temperatura, quando se utiliza um fluido refrigerante. Se a temperatura da peça estiver acima da temperatura de *film-boiling*, a temperatura da peça aumenta dramaticamente e pode resultar na queima. O início do *film-boiling* poderia ser detectado no processo pelas medidas nas variações da força, potência ou emissão acústica (EA). Assim, o controle adaptativo do dano térmico no processo de retificação seria possível de ser realizado com a utilização do critério do *film-boiling*, e poderia ser usado para interromper o processo mesmo antes do dano térmico ocorrer.

Shafto apud (1975) postulou que o aumento rápido na temperatura é característica de um fenômeno conhecido como *burn-out*, o qual ocorre em tubos de ebulição. Para uma temperatura crítica, referente à temperatura de *burn-out*, existe um colapso no mecanismo de transferência de calor, o qual resulta em um rápido crescimento da temperatura. Quando a temperatura atinge valores por volta de 100 °C, a água entra em ebulição causando bolhas na superfície do aquecedor. Um aumento além da temperatura de ebulição faz com que todas as bolhas se juntem, formando uma camada de vapor sobre a superfície, o chamado *Film-boiling*. A transferência de calor através deste filme é muito mais difícil, causando assim um aumento repentino da temperatura.

Yasui & Tsukuda (1983) mediram a temperatura na superfície da peça utilizando como fluido refrigerante óleo, água e também a seco. Eles verificaram que a uma temperatura acima do ponto de ebulição de cada fluido, a superfície da peça atingia rapidamente a temperatura correspondente àquela verificada para a retificação a seco. Em outras palavras, os fluidos deixavam de ser efetivos. Em estudo posterior, Salmon (1988) observou experimentalmente a formação de um filme de vapor na superfície da peça, imediatamente abaixo da zona de contato.

Segundo Badger & Torrance (2000), as classes de danos térmicos são divididas em:

- Queima oxidada, causada por uma fina camada superficial de metal oxidado e refrigerante, descoloração da peça. Esta descoloração normalmente é cosmética e frequentemente ocorre exteriormente na parte que sofreu algum dano metalúrgico. Esse tipo de queima pode ser observado na superfície retificada e ou próximo a ela, onde as temperaturas são altas para dadas condições. Assim, é um pobre indicador de que houve dano térmico, porque ele é imprevisível.
- Amolecimento térmico ocorre quando a temperatura de retificação ultrapassa a temperatura de revenimento do material da peça. O sobre-revenimento causa amolecimento da superfície da peça.
- Tensão residual é causada pela expansão térmica da peça além do seu limite de tensão, submetendo o material próximo da superfície a tensões constantes. Esta tensão degrada a vida de fadiga do material e, em casos extremos, causa trincas imediatas. A profundidade e severidade da trinca dependem da temperatura de retificação e do material.
- Queima endurecida é causada pela mudança de fase metalúrgica no material quando a temperatura de retificação ultrapassa a temperatura de austenitização, criando uma dura e frágil camada de martensita sem revenimento. Para tornar ainda pior o problema, queima

endurecida é acompanhada por uma tensão residual secundária, porque o material recentemente formado tem uma densidade maior que o material original.

Modelos baseados na abordagem anterior limitam a aplicação de controle no processo de retificação, porque o critério da queima do modelo depende somente da temperatura a qual é difícil ser medida no processo. A predição do campo térmico pode também não ser perfeita porque o modelo requer um parâmetro empírico do processo, isto é, a parte da potência gerada no processo responsável pelo calor que entra na peça, o qual é difícil determinar. Além disso, esses modelos não consideram o dano na forma de tensão residual, o qual pode ocorrer mesmo abaixo da temperatura crítica de queima (Kim, 1997). Por outro lado, o início do “*film-boiling*” pode ser detectado facilmente no processo pelas medidas nas variações da força, potência, ou Emissão Acústica (EA). Assim, o controle adaptativo do dano térmico no processo de retificação é possível ser realizado com a utilização do critério do “*film-boiling*”, e pode ser usado para interromper o processo mesmo antes do dano térmico ocorrer. No entanto, pesquisas têm sido realizadas procurando-se encontrar uma metodologia que seja praticável e de viável implementação na indústria, mas ainda sem muito sucesso no tocante à predição da queima, antes da peça ser danificada.

3.4 MONITORAMENTO E CONTROLE DO PROCESSO DE RETIFICAÇÃO

Durante o progresso humano de um estado primitivo até o presente, o mundo tecnológico foi marcado pelo desenvolvimento e aperfeiçoamento de novos métodos de controlar o ambiente. O termo controle está relacionado com métodos de fazer com que valores específicos sejam atribuídos a determinado parâmetro do sistema a ser controlado (Johnson, 1997). Os processos de manufatura de precisão, especialmente a retificação, têm requerido grande habilidade de sensoriamento e experiência do operador humano para assegurar boa qualidade superficial das peças e manter as precisões por elas exigidas. A falta de operadores habilidosos nos últimos anos vem acelerando a necessidade de estabelecer sistemas de retificação autônomos que minimizem a intervenção humana (Inasaki & Okamura, 1985; Felipe Junior, 1996; Aguiar, 1997). Um dos maiores obstáculos para se atingir a completa automatização do processo de usinagem dentro de sistemas integrados e flexíveis de manufatura é o desenvolvimento do que pode ser chamado de usinagem não assistida pelo homem, isto é, um processo no qual o estabelecimento do momento de troca da ferramenta, a própria troca da ferramenta e a mudança das condições de corte visando a otimização do processo não necessitam da intervenção do homem. Para isto, o desenvolvimento de um sistema de monitoramento e controle do processo, em tempo real, é de fundamental importância (Diniz et al., 1991; Souza, 1999; Aguiar et al., 2001). A

implantação de processos inteligentes na indústria utilizando máquinas comandadas em umericamente está crescendo. No entanto, o sistema denominado Controle Numérico Computadorizado (CNC) é insuficientemente confiável para operar sem a interação humana. É comum observar operadores de máquinas usando o sistema CNC simplesmente para corrigir os parâmetros do processo ou identificar o desgaste e o fim da vida da ferramenta (Aguiar et al., 1999).

Segundo Inasaki (1999), existem três importantes objetivos no monitoramento do processo de retificação: detectar problemas que ocorrem durante o processo; fornecer informações para otimizar o processo; e contribuir com o estabelecimento de um banco de dados necessário para determinar a configuração dos parâmetros de controle. A ampla faixa de variáveis de influência que afetam o processo e os inúmeros parâmetros descritivos para a qualidade do produto dificultam ainda mais a predição confiável do comportamento do processo (König & Knop, 1991). Tomando como exemplo o processo de retificação cilíndrica de mergulho, existem muitos parâmetros a serem pré-determinados que estão relacionados com a seleção do rebolo e do fluido de refrigeração. Estes parâmetros são: velocidade do rebolo, velocidade da peça e avanço. Dentre os parâmetros citados, o que mais influencia no resultado da retificação é a profundidade de corte. Outro fator preponderante é a definição do ciclo de retificação que consiste em determinar a rugosidade desejada, o término da operação e o período de *sparkout*. A informação obtida durante o monitoramento do sistema pode ser usada para minimizar o tempo do ciclo de retificação e aumentar a qualidade do processo (Inasaki, 1999).

3.4.1 Queima e seu Monitoramento no Processo de Retificação Utilizando Sinais de Emissão Acústica e Potência de corte.

Webster et al. (1994) têm mostrado que a medida do sinal de emissão acústica é significativamente mais sensível às variações das condições de retificação do que medidas de força e potência e, portanto fornece uma técnica mais promissora para o monitoramento “on-line” do processo. A emissão acústica (EA) pode ser definida como sendo ondas de tensão elástica gerada como um resultado da liberação rápida de energia de deformação dentro de um material submetido a um estímulo externo, devido ao rearranjo de sua estrutura. Estas ondas de tensão produzem deslocamentos na superfície do material o que pode ser detectado por um sensor piezelétrico que transforma estes deslocamentos em sinais elétricos (Nondestructive Testing Handbook, 1987; Diniz et al., 1991; Hassui et al., 1998; Dolinsek & Kopac, 1999; Li, 2002).

Sua faixa de frequência gira em torno de 50 kHz a 1000 kHz, que está acima da faixa de muitos ruídos vindos de fontes exteriores ao próprio processo de retificação. Sendo assim, é um método sensível e adequado para monitorar o processo de retificação (Oliveira, 1998; Hassui et al., 1998). Para Diniz (1991), o monitoramento de processos de usinagem utilizando emissão acústica apresenta algumas vantagens em relação a outros métodos, dentre elas:

- o sensor é simples, barato e pequeno (pouco intrusivo);
- as fontes de emissão acústica estão diretamente relacionadas com o processo de corte;
- não sofre influência de ruídos e vibrações mecânicas por captar um sinal em alta frequência (50 kHz a 1MHz).

As origens da emissão acústica no processo são decorrentes principalmente da fratura do grão e do ligante, fissura do grão e fricção entre o grão abrasivo e a peça-obra, todos diretamente ligados ao processo de formação de cavaco e desgaste do rebolo. Com o sinal de emissão acústica é possível determinar o fim do *sparkout*, que é muito importante para diminuir o ciclo de retificação (Hassui et al., 1998). O sinal de emissão acústica tem sido usado como um método de teste não destrutivo para avaliação da integridade estrutural de materiais desde o fim da década de 1960. Artigos técnicos da Alemanha, Japão e EUA têm mostrado pesquisas que tentam relacionar sinais de emissão acústica a aspectos mais complicados do processo de retificação, incluindo a detecção de quebra (Chang & Dornfeld, 1993), queima e trincas (Blum & Dornfeld, 1990; Koenig & Klumpen, 1993; Aguiar, 1997; Pansanato, 2001), e a transição do modo dúctil/frágil (Bifano & Yi, 1992). Estudos têm sido realizados também no monitoramento do desgaste da ferramenta (Waschkies et al., 1994; Dolinsek, 1999; Li, 2002) e na detecção de trincas devido à fadiga (Berkovits & Fang, 1995). Vieira & Oliveira (2002) desenvolveram uma abordagem de detecção de falhas e caracterização do processo de retificação centerless, o qual exigiu a criação de um *software* capaz de gerar um mapa digital da variação da profundidade de contato instantâneo da peça com o rebolo ao longo de cada volta do mesmo. Para isso, foi utilizado o sinal de emissão acústica medido durante o processo. Pelo padrão do mapa é possível reconhecer falhas ocorridas durante a retificação, pois dependendo de como ocorre a variação da profundidade instantânea de corte, o padrão gráfico apresenta aspectos diferentes.

O parâmetro predominantemente estudado em pesquisas prévias usando emissão acústica tem sido o valor médio quadrático (RMS) do sinal de EA filtrado (EA_{rms}) sobre uma banda de frequência cuidadosamente selecionada. Esse sinal tem sido um parâmetro razoável de estudo, pois o processo de retificação é muito rico em ondas sonoras, contendo portanto muita informação acústica disponível, sendo por isso utilizado como foco de pesquisas

anteriores e atuais, e também por limitações tecnológicas (Aguiar et al., 1998). Aguiar (1997) tem demonstrado que o sinal RMS de emissão acústica e o sinal de potência de corte combinados podem fornecer parâmetros expressivos para a indicação da queima da peça na retificação plana. O referido pesquisador tem usado uma configuração onde se utilizou um sensor fixo de EA acoplado próximo da peça obra e um sensor de potência elétrica do motor de acionamento do rebolo para as medidas da força de corte. Da combinação entre os sinais, Aguiar (1997) obteve um parâmetro indicativo para a queima da peça, denominado DPO, o qual consiste da relação entre o desvio padrão do sinal RMS de emissão acústica e a potência média de corte por passada do rebolo. Embora para a maioria dos ensaios realizados o parâmetro DPO tenha se mostrado um indicador da queima, para alguns casos não se comportou da mesma maneira.

3.4.1.1 Parâmetro DPO

Segundo Aguiar (1997), o sinal de emissão acústica e o sinal de potência de corte combinados podem fornecer parâmetros expressivos para a indicação da queima da peça na retificação plana. Da combinação entre os sinais, Aguiar (1997) obteve um parâmetro indicativo para a queima da peça, denominado DPO, o qual consistia da relação entre o desvio padrão do sinal RMS de emissão acústica e a potência máxima de corte por passada do rebolo. Embora para a maioria dos ensaios realizados o parâmetro denominado DPO tenha se mostrado um indicador da queima, para alguns casos não se comportou da mesma maneira, conforme dito anteriormente.

A expressão da Equação 4 representa o parâmetro DPO.

$$DPO = std(EA_{rms}) \max(Pot) \quad (\text{Eq. 4})$$

onde,

$std(EA_{rms})$: desvio padrão da emissão acústica;

$\max(Pot)$: potência máxima na passada;

3.4.1.2 Parâmetro DAREA

Segundo Dotto (2004), este parâmetro é calculado pela somatória do sinal de potência elevado pela somatória do sinal de Emissão Acústica RMS normalizado. A expressão a seguir representa o parâmetro DAREA.

$$DAREA = \left(\sum_{i=1}^{i=m} POT(i) \right) \sum_{i=1}^{i=m} \left(\frac{EA(i)}{EA_{MAX}} \right) \quad (\text{Eq. 5})$$

onde,

i : índice que varia de 1 até m pontos de cada passada;

m : número de pontos da passada;

$POT(i)$: valor instantâneo da potência;

$EA(i)$: valor instantâneo do sinal de Emissão Acústica RMS;

EA_{MAX} : valor máximo de Emissão Acústica RMS na passada;

Mais uma vez a amplitude do sinal não tem significado matemático, mas a variação da amplitude deste parâmetro indica claramente onde houve ocorrência da queima severa.

3.4.1.3 Parâmetro DIFP

Segundo Dotto (2004), dentre os diversos parâmetros desenvolvidos, pode-se considerar o parâmetro DIFP extremamente promissor, pois apresenta características muito próximas do DPO, entretanto, esse não envolve a potência máxima e sim a sua variação. Considerar a amplitude do sinal de potência no cálculo de um parâmetro pode comprometer a sua análise. Isso porque o sinal de potência depende dos valores de tensão e corrente obtidos através da rede elétrica. Além do valor de potência poder alterar sua amplitude dependendo da forma de onda presente na rede elétrica (tensão ou corrente), torna-se necessário redefinir o parâmetro para cada diferente tipo motor que for utilizado para girar o rebolo, deixando assim o sinal da potência muito susceptível a variações do meio.

Quando a análise foi realizada com base na variação da potência esse tipo de problema foi reduzido, deixando o sistema como um todo mais estável.

Durante a extração de passadas são criados triângulos que definem a região das passadas válidas. Na Figura 5 pode-se notar este triângulo formado pelos vértices O, I e II. O parâmetro DIFP na verdade utiliza a reta crescente gerada na detecção de passadas como coeficiente de variação. O seno do ângulo alfa (α) é calculado e multiplicado pela média da emissão acústica e multiplicado pela potência máxima vezes um fator de 100 é usado na equação. Percebe-se também que o sinal de potência continua presente na fórmula, entretanto, agora ele aparece multiplicado pelo alfa da reta crescente e, assim, menos susceptível a variação da amplitude.




Figura 3.5 – Ilustração do algoritmo de extração de passadas no sinal de potência (Dotto, 2004)

A expressão da Equação 6 representa o parâmetro DIFP.

$$DIFP = 100 \text{sen}(\alpha) \text{MAX}(POT) \text{MÉDIA}(EA) \quad (\text{Eq. 6})$$

onde,

$\text{sen}(\alpha)$: seno do ângulo formado entre a reta crescente presente na extração de passadas do sinal de potência;

$\text{MAX}(POT)$: máxima potência presente na passada;

$\text{MÉDIA}(EA)$: média do sinal de Emissão Acústica na passada;

3.4.1.4 Parâmetro DPKS

Segundo Dotto (2004), este parâmetro surgiu da necessidade de se aumentar a sensibilidade do parâmetro DPO, entretanto, sem necessariamente se preocupar com a sua amplitude e sim com a variação entre as passadas. Através desse parâmetro, pretendeu-se encontrar o momento exato onde a queima teve início. O DPKS é calculado pelo desvio padrão da emissão acústica multiplicado pela somatória da potência subtraída do seu desvio padrão elevada à quarta potência.

A expressão da Equação 7 representa o parâmetro DPKS.

$$DPKS = \left(\sum_{i=1}^{i=m} (POT(i) - \text{std}(POT))^4 \right) \text{std}(EA) \quad (\text{Eq. 7})$$

Onde:

i : índice da potência que varia de 1 até m pontos de cada passada;

m : número de pontos da passada;

$POT(i)$: valor instantâneo da potência;

$\text{std}(POT)$: desvio padrão da potência na passada;

$\text{std}(EA)$: desvio padrão da Emissão Acústica RMS da passada.

3.5 REDES NEURAIS ARTIFICIAIS - RNA

O trabalho pioneiro das redes neurais foi realizado no ano de 1943, pelo neurofisiologista Warren McCulloch, do MIT (Massachusetts Institute of Technology), e pelo matemático Walter Pitts, da Universidade de Illinois, os quais fizeram uma analogia entre células nervosas vivas e o processo eletrônico com o objetivo de criar um modelo matemático. O trabalho consistia em um modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio biológico (Tafner, 2006a). Desde então, mais

enfaticamente a partir da década de 1980, diversos modelos de redes neurais artificiais têm surgido com o propósito de desenvolver e aplicar esta tecnologia. Algumas destas propostas tendem a aperfeiçoar mecanismos internos da rede neural para aplicação na indústria e negócios, outras procuram aproximá-las ainda mais dos modelos biológicos originais (Tafner, 2006b). De acordo com Haykin (2001), uma rede neural artificial é um processador distribuído de forma paralela e constituído de unidades de processamento simples, que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso. Sendo assim, as redes neurais artificiais (RNA) através de um modelo matemático inspirado na estrutura neural, adquirem conhecimento através da experiência.

Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento. Já o cérebro de um mamífero pode ter bilhões de neurônios. O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios. Esses têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída. Os neurônios se comunicam através de sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre os mesmos (Carvalho, 2006). Os impulsos recebidos por um neurônio “A”, em um determinado momento, são processados, e atingindo um dado limiar de ação, o neurônio “A” dispara, produzindo uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de um outro neurônio “B”. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio “B”. Esse processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor. Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 10 bilhões de neurônios, e o número de sinapses é de mais de 60 trilhões, possibilitando a formação de redes muito complexas (Haykin, 2001). O neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico. Assim sendo, os dendritos foram substituídos por entradas, cujas ligações com o corpo celular artificial são realizadas por elementos denominados de peso (simulando as sinapses). Os estímulos captados pelas entradas são processados pela função de soma, e o limiar de disparo do neurônio biológico é substituído pela função de ativação (Tafner, 2006b). A representação de um neurônio biológico pode ser observada na Figura 3.6.




Figura 3.6 – Neurônio biológico (Haykin, 2001)

Combinando diversos neurônios artificiais podemos formar o que é chamado de rede neural artificial. As entradas, simulando uma área de captação de estímulos, podem ser conectadas em muitos neurônios, resultando, assim, em uma série de saídas. Cada neurônio representa uma saída. Estas conexões, em comparação com o sistema biológico, representam o contato dos dendritos com outros neurônios, formando assim as sinapses. A função da conexão em si é transformar o sinal de saída de um neurônio em um sinal de entrada de outro, ou ainda, orientar o sinal de saída para o mundo externo (mundo real). As diferentes possibilidades de conexões entre as camadas de neurônios podem gerar n números de estruturas diferentes. Depois de escolhida a rede neural e definida a sua arquitetura, segue uma fase chamada de treinamento, cuja tarefa é treinar a rede neural com uma coleção de estímulos (sinais complexos, voz, imagens, etc.) que se deseja que a rede reconheça quando em operação. Este aprendizado, nada mais é do que modificações sucessivas nos pesos dos neurônios de forma que estes classifiquem as entradas apresentadas. Afirma-se que a rede neural aprendeu quando esta passa a reconhecer todas as entradas apresentadas durante a fase de treinamento. Assim traduz-se o aprendizado da rede neural, pois, havendo pelo menos um neurônio que represente uma determinada informação (um estímulo apresentado na entrada), sempre que esse estímulo for apresentado a essa rede neural, aquele neurônio que foi treinado para representá-lo, automaticamente irá ser disparado, informando assim, qual o estímulo que foi apresentado para a rede neural. Uma forte característica das redes neurais é a capacidade de reconhecer variações dos estímulos treinados. Isto significa, por exemplo, que apresentando um estímulo “x” qualquer, semelhante a um estímulo “y” que fez parte do conjunto de treinamento, existe uma grande probabilidade de que “x” seja reconhecido como o “y” treinado, revelando assim a capacidade de generalização da rede neural artificial. A propriedade mais importante das redes neurais é a habilidade de aprender seu ambiente e com isso melhorar seu desempenho. Isto é realizado por meio de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Os conceitos explorados anteriormente

demonstram a utilidade desta técnica para fins de otimização, interpolação e predição do comportamento das variáveis de entrada e saída do processo, podendo-se fazer o mapeamento de uma série de condições, sabendo-se antecipadamente os possíveis resultados (Carvalho, 2006). Inúmeras aplicações surgiram desde a década de 1980, e a pesquisa nesta área é considerada uma das mais promissoras em informática e auxiliando também as demais ciências. As redes neurais artificiais têm sido utilizadas em várias aplicações, tais como:

- ❖ reconhecimento de padrões;
- ❖ processamento de sinais;
- ❖ processamento de fala;
- ❖ visão e robótica;
- ❖ identificação e controle;
- ❖ otimização de sistemas e processos; e muitas outras.

Nos primórdios de seu desenvolvimento, as redes neurais artificiais eram emuladas por meio de circuitos analógicos. A energia correspondente às conexões entre os neurônios, ou seja, as sinapses, eram controladas por potenciômetros. Atualmente, é mais comum a utilização de um programa para o treinamento e simulação das redes. Uma tendência bastante recente é a implementação de redes neurais em circuitos digitais, visando a maximização de sua velocidade de processamento.

A implementação de redes com circuitos digitais é alcançada por meio de arquiteturas digitais que permitam o processamento de dados de forma paralela. Normalmente, as implementações via *hardware* são fornecidas na forma de placas que podem ser acopladas a microcomputadores ou estações de trabalho. Pode-se afirmar que as redes neurais são o que há de mais avançado em termos de representação do conhecimento. Defronta-se na realidade com um sistema capaz de agir de maneira próxima a forma como os seres humanos adquirem e representam seu conhecimento. Baseado em estudos neurológicos, avanços matemáticos e computacionais, o desenvolvimento das redes neurais procurou formalizar um padrão matemático para as reações elétricas dos neurônios humanos. Desta forma, foi possível estabelecer uma representação computacional para os procedimentos da forma como se comporta o cérebro diante de suas diversas tarefas.

3.5.1 O Neurônio Artificial

Na prática, as redes neurais artificiais consistem de um grupo de elementos chamados de neurônios artificiais, que são interligados com outros grupos de neurônios através de

conexões, chamadas de sinapses artificiais, as quais permitem que informações possam fluir entre os vários grupos ou camadas de neurônios.




Figura 3.7 - Neurônio Artificial onde: \mathbf{x} é o vetor entrada; \mathbf{w} o vetor peso, θ_k o *bias* e \mathbf{y}_k a saída do neurônio \mathbf{k} (Haykin, 2001 - Adaptada).

Em essência, um conjunto de entradas (vetor \mathbf{x}) é aplicado a um neurônio artificial, cada uma representando uma saída de outro neurônio conforme Figura 3.7.

Cada entrada é multiplicada por um peso correspondente (vetor \mathbf{w}), analogamente, ao poder da sinapse. Os pesos das entradas são somados para determinar o nível de ativação do neurônio, este é ainda adicionado a um valor limite θ , conhecido por *bias* (polarização, limiar de excitação, *threshold*) ou, valor abaixo do qual, a saída é nula. Em outras palavras, um neurônio corresponde a uma soma ponderada de entradas, soma esta aplicada a uma função de ativação não-linear ou linear e contínua. Em termos matemáticos pode-se descrever um neurônio \mathbf{k} escrevendo as Equações 8 e 9 (Haykin, 2001):

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (\text{Eq. 8})$$

$$y_k = \varphi(u_k + \theta_k) = \varphi(v_k) \quad (\text{Eq. 9})$$

Portanto, a função de ativação φ se encarrega de propagar o estado de ativação como estímulo para outros neurônios.

Tabela 3.1 – Tipos de funções de ativação e suas representações gráficas (Haykin, 2001)

Função	Sem polarização	Com polarização
Degrau		
Degrau Simétrico		
Linear		
Logística Sigmoidal		
Tangente Sigmoidal		

Os tipos mais utilizados de funções de ativação (Tabela 3.1) são:

- ❖ **Função degrau:** limita a saída do neurônio a apenas dois valores (binário: 0 ou 1, ou bipolar: -1 ou 1). Normalmente é utilizada para criar neurônios que tomem decisões binárias, como nos classificadores. É limitada (*bounded*), porém não é derivável;
- ❖ **Função linear:** não é limitada. Neurônios com esta função de propagação podem ser utilizados como aproximadores lineares;
- ❖ **Função sigmoidal (logística):** permite que a entrada assuma qualquer valor no intervalo $(-\infty$ e $+\infty)$ e os comprime para o intervalo $[0,+1]$. É a função geralmente adotada em redes neurais em virtude de ser contínua, monotônica, não linear e facilmente diferenciável em qualquer ponto; e

- ❖ **Função tangente hiperbólica:** mapeia a entrada dos neurônios no intervalo $[-1,+1]$. Possui as mesmas características e emprego da função logística sigmoideal, possibilitando que as saídas sejam simétricas.

Cada neurônio realiza uma combinação linear de suas entradas seguida da aplicação de uma função definida e posteriormente transfere estes dados aos posteriores. Desta forma, as redes neurais trabalham com seqüências de operações matemáticas com matrizes de dados podendo ser interpretadas como uma estrutura de matrizes. Por restrições óbvias inerentes a todo conhecimento incipiente, as redes neurais não estão capacitadas a lidar com uma diversidade de temas, como o faz o cérebro humano. Atuando sobre um tema específico, a rede assimila o conhecimento sobre esse, não por meio de regras como um ser humano na escola, mas pela experimentação como um ser humano na prática. A rede deve ser treinada sobre o tema, ou seja, são fornecidos dados de entrada e implementadas propagações de forma que a alteração dos pesos ao longo da rede forneça uma saída compatível com a resposta conhecida àquele estímulo predeterminado. Desta forma, balanceia-se os pesos até que se obtenha um padrão de respostas aos estímulos, compatível com o que se conhece. Todo conhecimento de uma rede neural está armazenado, então, em suas sinapses, ou seja, nos pesos relativos às conexões entre os neurônios.

3.5.2 Arquitetura da RNA

A definição da arquitetura de uma rede neural é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problemas que pode ser tratado pela rede (Haykin, 2001).

Fazem parte da definição da arquitetura os seguintes parâmetros:

- ❖ número de camadas da rede;
- ❖ número de neurônios em cada camada;
- ❖ tipo de conexão entre os neurônios; e
- ❖ topologia da rede.

Um esquema de classificação simples pode ser realizado com algumas informações que descrevem uma rede neural, tais como:

- ❖ **topologia:** como as funções são interconectadas;
- ❖ **arquitetura:** o tipo e a utilização da rede neural;
- ❖ **modelo do neurônio:** as funções utilizadas;
- ❖ **algoritmo de treinamento:** como os parâmetros são configurados; e
- ❖ **escalonamento da operação:** a sincronização das interações entre funções.

Outra classificação das redes neurais é quanto à forma de aprendizado em:

- ❖ aprendizado supervisionado (ou associativo);
- ❖ aprendizado não-supervisionado (ou auto-organizado); e
- ❖ aprendizado híbrido.

No treinamento supervisionado, é incluída ao processo de treinamento uma etapa de verificação dos resultados calculados pela rede neural durante o treinamento. O erro observado a partir da comparação de resultados fornecidos por um conjunto de treinamento com os resultados calculados pela rede, que pode ser utilizado para ajustar os pesos das sinapses de forma a melhorar a resposta da rede, melhorando desta forma a precisão da rede quando simulando o fenômeno estudado. Nas redes neurais onde o treinamento não é supervisionado ocorre um processo interno de organização dos dados que conduz a um grau ótimo de ajuste. Estas redes auto-organizadas podem, por exemplo, dividir dados fornecidos em categorias, em função do grau de similaridade entre estes, de forma totalmente automática. Já o treinamento híbrido combina a aprendizagem supervisionada e a não-supervisionada. Uma RNA função de base radial admite esta forma de aprendizado, onde a primeira camada de conexões é treinada de forma não-supervisionada e a segunda de forma supervisionada (Haykin, 2001).

Quanto ao número de camadas, pode-se ter:

- ❖ **redes de camada única:** só existe um nó entre qualquer entrada e saída da rede neural artificial; e
- ❖ **redes de múltiplas camadas:** existe um ou mais neurônios entre a camada de entrada e a camada de saída da rede.

Além destas classificações, outras podem ser levadas em consideração para a classificação das redes, como por exemplo, a forma que se processa o fluxo de dados. Em função do fluxo de dados, estas podem propagá-los unidirecionalmente, ou seja, apenas para frente (*feed-forward networks*) ou nos dois sentidos (*feedback network*). Uma característica fundamental do tipo de rede *feed-forward* é a disposição dos neurônios em camadas. Deve haver no mínimo duas camadas: a de entrada de dados e a de saída de resultados (Haykin, 2001). Uma vez que o desempenho de redes neurais deste tipo que contenham apenas duas camadas é muito limitado, normalmente inclui-se pelo menos uma camada intermediária entre as duas, também chamada de camada oculta ou camada escondida. Cada neurônio está ligado a todos os neurônios das camadas vizinhas, mas não há ligações entre os neurônios de uma mesma camada. O comportamento deste tipo de rede é estático e se comporta de modo a tornar sua saída um reflexo da respectiva entrada. Essa deve ser treinada de modo a produzir

os resultados desejados a partir da apresentação de dados reais. As redes do tipo recorrentes, ou *feedback network* se caracterizam por apresentar o fluxo de dados de maneira multidirecional. Seu comportamento é dinâmico. Note-se que neste caso não há camadas discretas de neurônios, há uma total integração entre os dados de entrada e os resultados obtidos, pois todos os neurônios são ligados entre si. Seu treinamento é feito de modo a minimizar a energia da rede, gerando um comportamento independente.

3.5.3 Aplicações

A rede neural artificial representa hoje uma vigorosa área de pesquisa multidisciplinar que possui uma grande gama de áreas de atuação. Algumas áreas potenciais de atuação de redes neurais são as seguintes (HAYKIN, 2001):

- ❖ **Reconhecimento de padrões:** a tarefa a ser desempenhada é a de atribuir um padrão de entrada a uma das várias classes pré-definidas. Essa aplicação tem sua atuação no reconhecimento de caracteres, reconhecimento de voz, análise de crédito, etc.
- ❖ **Clustering/Categorização:** explorar as semelhanças entre padrões e agrupar padrões parecidos, possibilitando assim, a aplicação em compactação de dados, garimpagem de dados, etc.
- ❖ **Aproximação de funções:** a rede é capaz de estimar os parâmetros de uma função desconhecida ou muito complexa, resolvendo desta maneira problemas de modelagem científica e de engenharia.
- ❖ **Previsão/Estimação:** dado um conjunto de exemplos referentes a intervalos de tempo decorrido, prever situações futuras. Redes modeladas desta maneira são úteis em sistemas dinâmicos, na previsão do tempo e de mercados financeiros;
- ❖ **Otimização:** minimizar ou maximizar uma função sujeita a um conjunto de restrições. Os resultados obtidos, com tais ferramentas, em processos de produção são notáveis.
- ❖ **Memórias associativas (endereçamento pelo conteúdo):** a tarefa de recuperar itens corretos mesmo que a entrada seja parcial, e
- ❖ **Controle:** gerar ações de controle para que o sistema siga trajetórias especificadas por modelos de referência.

Em sua essência, redes neurais tendem a trabalhar com os dados de uma forma inteiramente diferente dos sistemas baseados em algoritmos ou conjuntos de regras. Enquanto as redes neurais processam dados com base em transformações, a computação tradicional faz uso de algoritmos que representam regras. A experiência tem mostrado que essas duas

abordagens de processamento da informação são complementares do ponto de vista operacional, mas incompatíveis em termos conceituais (Tanuri, 2006). De fato, as redes neurais não prescindem totalmente da computação convencional. Afinal, em qualquer aplicação, a aquisição dos dados, sua formatação e a saída dos resultados ainda utiliza este recurso. Redes neurais são geralmente rotinas que podem ser combinadas com programas nos quais sua capacidade se faz necessária (Rabello, 2006).

Ressalta-se que a rede neural artificial foi utilizada neste projeto de pesquisa como uma ferramenta para a predição de características da peça (rugosidade e circularidade). Estudos anteriores comprovaram a eficácia desta ferramenta na retificação para se prever a queima superficial de peças (Nathan, 1999). Assim esta técnica pode também vir a ser utilizada para a predição de outras características do processo.

3.5.4 Principais características das Redes Neurais Artificiais

As principais características das RNA's podem ser resumidas como segue (Haykin, 2001):

- ❖ **Aprendizado através de exemplos:** com um conjunto de treinamento é realizado o ajuste e o treinamento da rede a fim de que o erro entre a saída desejada e a fornecida pela rede seja minimizada;
- ❖ **Capacidade de se adaptar ou aprender:** são capazes de se modificarem havendo uma mudança no comportamento do fenômeno estudado;
- ❖ **Capacidade de Generalização:** Uma vez treinada para um conceito, a RNA é capaz de trabalhar com conceitos similares que ainda não foram aprendidos e isto sem esforço complementar;
- ❖ **Agrupar ou organizar dados e informações:** Capacidade de organizar as informações em classes;
- ❖ **Tolerância à falhas:** A falha de um neurônio ou uma sinapse não degrada a resposta da rede; e
- ❖ **Auto-Organização:** Com o aprendizado, a rede automaticamente faz a sua organização interna.

Certas características das redes neurais, como tolerância a falhas, robustez e capacidade de implementar uma classe particular de transformações, são garantidas por teoremas matemáticos. Ou seja, estes asseguram que as redes neurais podem ser empregadas de forma útil e confiável. Além de teoremas matemáticos, a comprovação das características das redes neurais é, principalmente, comprovada nas suas aplicações práticas.

3.5.5 Treinamentos de Redes Neurais Artificiais

O processo de ajuste de uma rede neural artificial para determinado problema, consiste em um processo de aprendizado. Nesse processo de ajuste, os pesos sinápticos (matriz de pesos) são corrigidos de forma que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas (Haykin, 2001). A maneira como uma rede é treinada constitui em um padrão classificatório para as mesmas. Como já dito anteriormente, o treinamento das redes pode ser classificado em dois grupos (HAYKIN, 2001):

- ❖ **Supervisionado:** a rede é treinada para fornecer a saída desejada em relação a um estímulo de entrada específico. Como exemplo, têm-se as redes *Perceptrons*.
- ❖ **Não Supervisionado:** não precisa ficar sendo comparada constantemente a um valor de saída específica em relação aos estímulos de entradas. A rede se auto-organiza em relação a algum subconjunto de entradas cujos elementos possuem características similares. Como exemplo deste tipo de treinamento tem-se o aprendizado competitivo utilizado nas redes de *Kohonen*.

3.5.6 Tipos de RNA's

O modelo de rede neural artificial utilizada nesta pesquisa é o MLP (MultiLayer Perceptron), ou *Perceptron* de múltiplas camadas. Esse modelo de RNA se origina do *Perceptron* e por isso, nesta pesquisa, serão estudados estes dois exemplos com maior profundidade.

3.5.6.1 Perceptron

O *Perceptron* é uma forma simples de uma rede neural utilizada para a classificação de padrões. Construídas por apenas uma camada de neurônios (possuindo pesos e *bias*), incluindo o caso particular de apenas um neurônio, limitado a classificar padrões em duas classes. O *Perceptron* modela neurônios empregando uma soma ponderada de suas entradas ou sinapses e enviando o resultado +1 (um positivo) se esta soma for superior a um determinado limiar, caso não, o valor zero será nulo, ou ainda, -1 (um negativo) dependendo da função de ativação escolhida na modelagem da rede *Perceptron*. Pode-se notar com isso que as funções de ativação do *Perceptron* podem ser a função degrau para casos nos quais a resposta deva ser 0 ou +1, ou então a função degrau simétrico para situações nas quais a saída deve assumir os valores +1 e -1. Tipicamente as entradas e os pesos das conexões, nesse modelo, assumem valores reais, portanto, que podem ser positivos ou negativos. Se uma entrada correspondente a uma característica tender a disparar o peso sináptico associado a essa entrada terá seu valor como sendo positivo, pode-se então dizer que tal característica tem

função excitatória sobre o neurônio. Se o oposto ocorrer, ou seja, o neurônio for inibido por uma determinada característica, o valor do peso sináptico associado a essa entrada será negativo. Aprendizagem é o processo de modificar os valores dos pesos sinápticos e do limiar até que o mínimo erro quadrático entre a resposta da rede e o padrão fornecido pelo conjunto de treinamento possa ser atingido. O algoritmo de treinamento dos *Perceptrons* foi baseado nos estudos desenvolvidos em 1949 pelo biólogo *Hebb*. Esse propôs um princípio pelo qual o aprendizado em sistemas nervosos complexos poderia ser reduzido a um processo puramente local, em que a intensidade das conexões sinápticas é alterada em função dos erros detectáveis localmente (KOVACS, 1996). Pode-se então traduzir este princípio no algoritmo de treinamento do *Perceptron* da seguinte maneira:

$$\mathbf{w}_i^{k+1} = \mathbf{w}_i^k + \Delta \mathbf{w}_i \quad (\text{Eq. 10})$$

$$\Delta \mathbf{w}_i = \eta (\mathbf{y}_i^d - \mathbf{y}^d) \mathbf{x}_{ij}^d \quad (\text{Eq. 11})$$

11)

onde:

d é um índice que significa desejado;

w é a matriz de pesos;

x e **y** os vetores de entrada e saída respectivamente;

η é referido como taxa de aprendizado; e

i e **j** índices referentes às entradas e exemplos respectivamente.

Essa é uma regra local na medida que não depende dos valores das demais variáveis espalhadas pelo sistema. A saída do neurônio pode então ser calculada como:

$$\mathbf{y} = \text{sgn} \left(\sum_{i=1}^{n+1} \mathbf{w}_i \mathbf{x}_i \right) = \text{sgn}(\mathbf{w}^T \mathbf{x}) \quad (\text{Eq. 12})$$

Onde:

sgn denota a função sinal.

O processo de atualização da matriz de pesos atinge seu ótimo quando a redução do gradiente do erro quadrático entre as saídas desejadas e as obtidas pelo *Perceptron* atingem seu mínimo. O *Perceptron*, depois de treinado, separa linearmente duas coleções através de um hiperplano contido no hiperespaço desses conjuntos. Esse hiperplano é chamado de superfície de decisão. A aprendizagem, do ponto de vista geométrico, pode então ser resumida a um processo de determinação desse hiperplano no espaço multidimensional das entradas. O que Minsky e Papert (1999), discutiam no texto *Perceptrons*, é o fato de que embora o

teorema da convergência garantisse a classificação correta de dados linearmente separáveis, a maioria dos problemas não fornece dados com esta característica. Um exemplo de um problema simples com dados não separáveis linearmente é a função Booleana OU Exclusivo (XOR). Para problemas com características não lineares o *Perceptron* é incapaz de fornecer uma hipersuperfície de separação adequada ao correto tratamento do problema, pois esta simplesmente não existe, Figura 3.8.

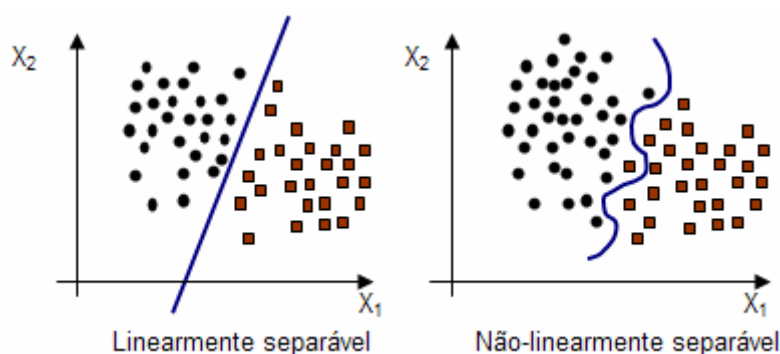


Figura 3.8 – Diferenças entre um problema linearmente separável e outro não-linearmente separável (Oliveira, 2006)

Observa-se que a deficiência apresentada não está no algoritmo de aprendizagem para *Perceptrons*, mas no modo como este tipo de rede representa o conhecimento. A solução desse tipo de problema foi encontrada em arquiteturas de *Perceptrons* multicamadas (MLP) e da generalização da Regra Delta.

3.5.6.2 *Perceptron multicamadas e backpropagation*

Uma importante classe de redes neurais são as redes multicamadas, mais comumente chamadas *Perceptron* multicamadas. Essas redes consistem em uma camada de entrada, uma oculta e outra de saída, podendo, entretanto, dependendo das características do problema proposto, possuir mais de uma camada oculta na sua arquitetura. Todavia, o *Teorema da Aproximação Universal* afirma que uma única camada oculta é suficiente para um *Perceptron* de múltiplas camadas computar uma aproximação uniforme para um dado conjunto de treinamento representado pelo vetor de entrada x e a saída desejada (vetor y) (HAYKIN, 2001). O problema fica por conta do número ideal de neurônios desta camada. Alguns pesquisadores têm oferecido diretrizes para a escolha do melhor número de neurônios ocultos, porém sem demonstrações matemáticas, ficando a determinação deste parâmetro a cargo da experimentação. A rede multicamadas, ao contrário do *perceptron de Roseblatt* (ou simplesmente *Perceptron*), possui funções de ativação diferenciáveis em seus neurônios, isto

é, sem degraus. O número de neurônios na camada de entrada é igual ao número de variáveis de entrada do sistema, e cada um desses neurônios recebe uma entrada. A saída dos neurônios na camada de saída corresponde às saídas da rede. Esse tipo de rede pode ser utilizado para aproximação de funções, reconhecimento de padrões, controle e previsão de parâmetros de processos. Uma rede de *Perceptrons* multicamadas pode ser esquematizada como na Figura 3.9.




Figura 3.9 – Esquematização de uma rede *Perceptron* multicamadas (Haykin, 2001)

Os neurônios da primeira camada recebem todas as entradas do processo, passando então, estes sinais para as camadas subseqüentes, usando por exemplo, a função sigmoideal como função de ativação. Outras funções de ativação podem ser utilizadas, desde que sejam contínuas e diferenciáveis no seu domínio. Por este motivo, as funções do tipo sinal e degrau não são empregáveis em neurônios de redes multicamadas, pois não são diferenciáveis no seu domínio. Existem duas operações distintas durante a fase do treinamento de retropropagação. Cada vez que um par de treinamento é apresentado à rede, esta necessita de dois estágios para o seu ajuste: um para a frente (fase *forward*) e outro para trás (fase *backward*). A Figura 3.10 ilustra esta afirmação.

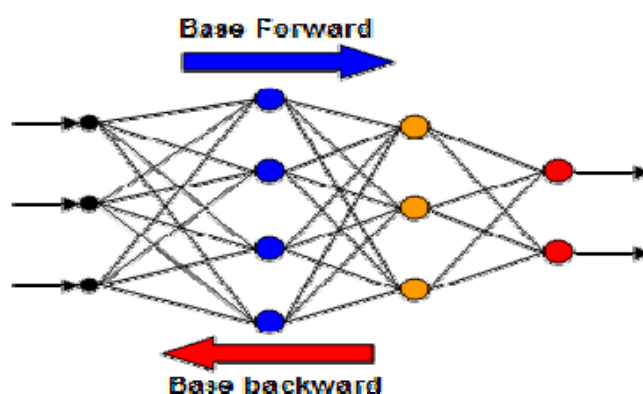


Figura 3.10 – Fase *forward* e *backward* do treinamento de retropropagação (Thomé & Oliveira, 2006)

A passagem para frente envolve apresentar um exemplo da entrada para a rede e deixar as ativações fluírem até chegarem à camada de saída. Durante a passagem para trás, o

produto da rede, obtido na passagem para frente, é comparado com a saída desejada, e as estimativas de erro são computadas para as unidades de saída. Os pesos conectados às unidades de saída devem então ser ajustados de forma a reduzir estes erros. Posteriormente é utilizada a estimativa de erro das camadas de saída a fim de derivar as estimativas de erro para as unidades de camadas ocultas. Desta forma, os erros são propagados para trás até a conexão, cuja raiz esteja na unidade de entrada. O algoritmo de *backpropagation* ajusta os valores das matrizes de peso em relação à direção oposta do gradiente da função erro quadrático. Entretanto, a utilização deste algoritmo na prática tende a convergir muito lentamente, exigindo assim um elevado esforço computacional para que o treinamento da rede seja realizado. Para contornar esse problema, várias técnicas de otimização têm sido incorporadas ao algoritmo de *backpropagation*, a fim de diminuir seu tempo de convergência e diminuir o esforço computacional exigido pelo mesmo. Dentre as técnicas de otimização mais utilizadas para este propósito destaca-se o algoritmo de *Levenberg-Marquardt*. O algoritmo de *Levenberg-Marquardt* é uma técnica baseada no método dos mínimos quadrados para modelos não lineares que pode ser incorporada ao algoritmo de *backpropagation*, a fim de aumentar a eficiência do processo de treinamento. Enquanto o algoritmo *backpropagation* é um método de descida do gradiente da função erro quadrático, o algoritmo de *Levenberg-Marquardt* é uma aproximação do método de Newton para sistemas não-lineares. Para saídas entre $[-1,1]$ o algoritmo de *backpropagation* torna-se mais eficiente quando se utiliza uma função de ativação assimétrica (Haykin, 2001).

3.5.7 Taxa de Aprendizado e Momento

Algumas considerações acerca dos valores empregados nestes parâmetros devem ser feitas. Se a taxa de aprendizado η for muito pequena implicará em uma convergência mais lenta, entretanto, se η for muito grande, a convergência pode tornar-se instável. Esse tipo de problema pode ser minimizado com o auxílio do Momento α , segundo as relações expressas em (Haykin, 2001).

Para:

- ❖ $\eta \rightarrow 0 \Leftrightarrow \alpha \rightarrow 1$: Aumenta a velocidade de convergência, com uma maior precisão; e
- ❖ $\eta \rightarrow 1 \Leftrightarrow \alpha \rightarrow 0$: A convergência é muito mais rápida, porém com uma menor precisão.

3.5.8 Validação Cruzada (Cross-Validation)

A validação cruzada é uma metodologia utilizada para selecionar uma arquitetura de *Perceptrons* multicamadas entre vários modelos candidatos. Nessa técnica, os seguintes passos devem ser seguidos (Haykin, 2001):

- ❖ particionar o conjunto de dados disponíveis em dois subconjuntos. Um destinado ao treinamento e estimação do modelo (conjunto de treinamento), e o outro usado para a avaliação do modelo (conjunto de teste);
- ❖ utilizar o mesmo conjunto de treinamento para treinar todos os modelos candidatos;
- ❖ após o treinamento, utilizar o conjunto de teste para avaliar e escolher o melhor modelo; e
- ❖ treinar o melhor modelo com todo o conjunto de dados, ou seja, com o conjunto de treinamento e o conjunto de teste.

3.5.9 Redes Neurais Artificiais Aplicadas na Manufatura

No passado, vários métodos baseados em áreas como, pesquisa operacional, estatística, simulação computacional e teoria de controle, foram desenvolvidos e aplicados na solução de uma ampla gama de problemas na manufatura.

Atualmente, a fabricação é caracterizada pela sua complexidade, pluralidade de disciplinas e crescente demanda de novas ferramentas e técnicas para a solução de difíceis problemas. As redes neurais artificiais oferecem uma nova e diferente alternativa para investigar e analisar os desafios tópicos relacionados à manufatura (Rajagopalan & Rajagopalan, 1996). A grande oferta de *softwares* e ferramentas de modelamento e implementação de RNA's tem dispensado a necessidade do engenheiro ser um especialista em inteligência artificial; deste modo, a RNA pode se comportar como uma caixa-preta no processo (Rowe et al., 1996).

As redes neurais são utilizadas para capturar características gerais entre variáveis de um sistema que são difíceis de relacionar analiticamente. Têm a capacidade de aprendizado ou de serem treinadas para determinadas tarefas, além da habilidade de formular abstrações e generalizações. Devido ao rápido desenvolvimento dos métodos e ferramentas relacionados à RNA, essa tem gerado um enorme interesse em soluções de problemas ligados à manufatura. As RNA's são utilizadas em áreas relacionadas à manufatura, tais como: planejamento e controle de processos; dimensionamento de sistemas para a manufatura; sistemas de tomada de decisão operacional; gerenciamento de robôs; e monitoramento.

As RNA's devem ser aplicadas em áreas nas quais há grande volume de dados e não exista um conhecimento estruturado sobre esses dados, desta forma, se tornam especialmente úteis no monitoramento e controle de processos de fabricação, onde as possibilidades de sensoriamento são vastas e fornecem informações valiosas sobre o processo, entretanto, muitas vezes de difícil inter-relacionamento. Observa-se um crescente aumento desse tipo de abordagem no tratamento de problemas relacionados às máquinas e processos nos últimos anos. Muitos são os exemplos de aplicações de RNA's em processos de usinagem e especificamente no processo de retificação. As redes neurais artificiais aplicadas ao processo de retificação são especialmente vantajosas, pois esse processo necessita de uma operação de altíssima qualidade e confiança para alcançar resultados satisfatórios. As RNA's são utilizadas no processo de retificação para: Seleção de parâmetros e otimização do processo de *creep feed*; seleção de parâmetros na operação de dressagem; monitoramento e otimização; seleção do tipo de rebolo e monitoramento do mesmo; e predição do tempo de queima, parâmetros do processo e finais da peça.

Teixeira (1999) investigou a condição da ferramenta de corte na fresagem de topo em um centro de usinagem utilizando RNA. Os dados colhidos para análise foram: sinal de um sensor de corrente, força na direção do avanço de fresado, e sinais gerados por dois acelerômetros, um posicionado no cabeçote do eixo árvore na direção do eixo de avanço e outro sobre a mesa. Através das informações geradas por esses sensores instalados no centro de usinagem foi acoplado ao sistema de monitoramento um outro de tomada de decisões, o qual apropriadamente interpretou as informações de entrada dos sensores associando-as aos padrões do estado da ferramenta. Foi utilizado o algoritmo "*Sequential Forward Search*", SFS, o qual previamente seleciona as características mais relevantes do comportamento do espectro do sinal dos sensores (da força, corrente e aceleração). A Rede Neural Artificial, foi utilizada para integrar a informação das frequências selecionadas e reconhecer a ocorrência do desgaste da ferramenta na operação de fresamento.

Kwak (2001) utilizou uma rede neural treinada pelo algoritmo *backpropagation* para a predição de problemas frequentemente encontrados no processo de retificação cilíndrica. Para tanto utilizou como dados de entrada para a rede o pico do sinal RMS, o pico da transformada rápida de Fourier, a contagem dos sinais acima do limiar e o desvio-padrão dos sinais de emissão acústica adquiridos por um sensor instalado no contraponto. Pela sua importância no referido processo, os problemas analisados foram a queima superficial e a vibração induzida, as quais interferem diretamente no acabamento da peça. Assim, os dados de saída da rede

eram as informações “queima ocorrida”, “vibração ocorrida” ou “andamento normal do processo”. A rede se mostrou eficiente na predição destes padrões.

Em uma pesquisa semelhante conduzida por Vijayaraghavan & Krishnamurthy (2001) a temperatura de queima foi estudada em função de sinais de emissão acústica, força normal de corte, vibração e número de ciclos na retificação plana. As amostras coletadas nos ensaios foram inseridas em uma rede neural cujos neurônios eram dispostos da seguinte forma: 4 neurônios na camada de entrada, 5 na oculta e um neurônio de saída (referente à temperatura de ocorrência da queima). O método se mostrou eficiente, o que reforça a eficácia do multisensoriamento e do método de RNA no monitoramento *online* do processo. Nathan (1999) realizou um trabalho semelhante, porém monitora a potência e a temperatura da região de corte, sendo esta última monitorada pelo faiscamento do processo a seco. Neste mesmo trabalho foi utilizada uma RNA com sucesso na predição da queima.

De acordo com Wang et al. (2001), um sistema de redes neurais artificiais é proposto a fim de se verificar a detecção da queima no processo de retificação. Esse fenômeno é decorrente de mudanças nas propriedades metalúrgicas dos materiais devido a uma usinagem severa ou até mesmo um método de fabricação inapropriado. O sinal de EA foi coletado para ser utilizado como um vetor na rede e como resultado final obteve-se a informação da ausência ou presença da queima. Concluiu-se que através dos treinamentos, a RNA obteve uma excelente desempenho neste trabalho.

Bicudo et al. (1996) apresenta em seu estudo, inovações tecnológicas atuais aplicadas especificamente na retificação, mas com extensão a todos os tipos de máquinas operatrizes. Verifica-se que a avaliação dos potenciais de novas tecnologias de produção baseia-se no aumento do desempenho da máquina, além da redução de custos de produção, a fim de reduzir ao extremo os tempos e custos de usinagens. Para isto utilizam-se de inúmeros artificios eletrônicos, bem como novos materiais de corte e componentes mecânicos.

Dentre as inovações mencionadas, pode-se citar os sistemas de controle da manufatura que com sensores dispostos em pontos estratégicos da máquina, consegue-se medir inúmeras variáveis do processo, de forma a interpretá-las e corrigi-las, se necessário, para o alcance das tolerâncias e qualidades exigidas. Esses, além disso, possibilitam que se realize simulações de usinagens (redes neurais artificiais) nas mais variadas condições, criando correlações entre as diversas variáveis do processo, de forma a haver um “equilíbrio inteligente” por parte da máquina durante a operação e fazendo um prognóstico da possível qualidade final (Bicudo et al., 1996). Contudo, como a aplicação dos artificios acima citados, opera-se perto dos limites máximos das máquinas-ferramentas, o que significa uma redução no quesito segurança do

trabalho. Desta forma, existe a necessidade da aplicação de dispositivos (denominados “módulos inteligentes”) que asseguram que a máquina não trabalhará acima dos limites pré-estabelecidos de usinagem.

4 MATERIAIS E MÉTODOS

Neste capítulo serão vistos a montagem e os equipamentos que foram necessários para a realização dos ensaios na retificadora.

O trabalho experimental foi realizado no Laboratório de Usinagem por Abrasão (LUA) do Departamento de Engenharia Mecânica da Universidade Estadual Paulista (UNESP), *campus* de Bauru.

A medição de microdureza após o ensaio na retificadora. O Laboratório de Aquisição e Processamento de Dados (LADAPS), do Departamento de Engenharia Elétrica da UNESP – Bauru, também foi utilizado, oferecendo suporte técnico no decorrer da pesquisa.

A preparação das peças, do fluido, o ajuste do sensor de emissão acústica estão detalhados dentro do conteúdo.

Para a obtenção dos resultados dos ensaios foram realizadas as seguintes etapas:

- O *software* de interface utilizado foi o LabVIEW que comanda a placa A/D durante a aquisição e salva os dados separadamente em arquivos binários do tipo I16.
- O *software* MATLAB, da empresa *The MathWorks, Inc.*, foi a ferramenta utilizada para o tratamento final dos dados obtidos nos ensaios;
- Extraídos vetores, através do gráfico gerado pelos sinais, o início e o fim da passada, ficando apenas com as aquisições durante o contato do rebolo com a peça;
- Placa de aquisição de dados DAQ, com 12 bits de precisão, do fabricante *National Instruments*, modelo PCI-6111, com máxima frequência de amostragem de 5,0 milhões de pontos por segundo;
- Respeitando os limites da placa, onde sua capacidade máxima de 2,5 milhões de amostras por segundo para cada canal, onde representou um tempo máximo de 4 segundos sem comprometer o saturamento do buffer.

4.1 EQUIPAMENTOS UTILIZADOS

Os ensaios de usinagem foram executados em uma máquina retificadora plana modelo RAPH – 1055, fabricada pela empresa SULMECANICA, que contém base magnética para fixação da peça conforme Figura 4.1.



Figura 4.1 - Retificadora plana modelo RAPH - 1055, *SULMECÂNICA*

4.2 BANCADA DE ENSAIO

Na retificadora estão acoplados dois motores:

- motor de rotação do rebolo (dois pólos): controlado pelo inversor de frequência WEG modelo CFW-02 380V de 7,5 cv, responsável pela velocidade tangencial do rebolo.
- motor do fuso: controlado pelo inversor de frequência WEG modelo CFW-02 de 5,0 cv. Responsável pela velocidade do fuso (deslocamento transversal), acionado para se fazer a dressagem.

O rebolo utilizado foi o de óxido de alumínio branco ART-FE-38A80PVH da NORTON indicado para operação de retificação plana com aços. Suas dimensões originais são 203,2 x 25,4 x 31,75 mm. Segundo Saint Gobain (2006) o rebolo tem as seguintes características contrutivas:

- ART – Tipo Reto
- FE – Ferramentaria
- 38A – Óxido de Alumínio branco – indicado para aços extremamente sensíveis à queima.
- 80 – Granulometria média 8-2000
- P – Dureza (escala de E à X)
- VH – Liga Vitrificada

A corrente e a tensão do inversor de frequência são monitoradas pelo módulo desenvolvido pelo LADAPS – Laboratório de Aquisição de Dados e Processamento de Sinais da Unesp-Bauru. De acordo com Aguiar (2003) o módulo converte os valores na potência conforme a Equação 13:

$$P_{ELÉTRICA} = 765,2.V - 3,37 \quad (\text{Eq. 13})$$

onde: V: é a tensão na saída do módulo [V];

P: é a potência elétrica do motor [W].

O sensor de emissão acústica utilizado foi o sensor de EA parafusado da Sensis Industrial, Figura 4.2, acoplado ao módulo de monitoramento DM42 do mesmo fabricante que condiciona o sinal em uma tensão proporcional.



Figura 4.2 – Fixação do sensor de emissão acústica

Após seus respectivos condicionadores os sinais de emissão acústica e de potência entram no bloco terminal NI BNC-2110 da National Instruments, que faz a interface dos módulos com a placa de aquisição.

Foi utilizada uma placa de aquisição de dados, DAQ, com 12 bits de precisão do fabricante National Instruments, modelo PCI-6111, com máxima frequência de amostragem de 5.000.000 amostras por segundo (5MSPS), que é acoplada em um microcomputador desktop. Além da instalação física, a placa foi iniciada via *software* LabVIEW para armazenamento dos dados em arquivos do tipo texto (Aguiar, 2003).

Os ajustes e parâmetros utilizados foram:

- Velocidade Tangencial de deslocamento da mesa retificadora: $V_w = 0,044$ m/s
- Velocidade Tangencial do rebolo: 60Hz inicial para $D_{REBOLO} = 167,80$ mm.

$$V_s = \pi f.D/2 = 30 \text{ m/s}$$

- Módulo EA (DM42):
 - Ganho de sinal = 1
 - Ganho de Entrada = 10
 - Redução de Ruído = 0
 - Filtro Passa Alta = 200 Hz
 - Sem Filtro passa baixa
 - Constante de tempo = 1 ms

A bancada de ensaio é exibida na Figura 4.3.




Figura 4.3 – Diagrama da bancada de ensaios

4.3 PREPARAÇÃO E REALIZAÇÃO DOS ENSAIOS

4.3.1 *Preparação dos Corpos de Prova*

Para realizar os ensaios utilizou-se onze corpos de prova (vinte e uma faces) em forma de prisma de dimensões 152 x 45 x 12 mm, aço ABNT 1020 com 3 faces na mesma profundidade de corte x 6 profundidades diferentes + 3 faces em degrau. Para cortar essas peças, foi utilizada serra e tiveram que ser faceadas em um torno. As peças foram retiradas da mesma chapa, pois isso garante que elas tenham a mesma procedência. Isso aproxima a dureza das peças por terem aproximadamente a mesma quantidade de carbono. Em seguida,

suas bordas foram limadas, retirando as rebarbas que ficaram nas peças. As peças foram tipografadas em cada uma de suas duas faces, lateralmente, indicando naquela face o sentido da usinagem e o valor da profundidade de corte a ser realizado, exemplificado na Figura 4.4. As peças foram lubrificadas com óleo para evitar a oxidação destas superfícies trabalhadas.



Figura 4.4 – Corpo de prova tipografado

Para retirar as marcas do *bit* do torno (ferramenta de desbaste), antes de realizar o ensaio, foi preciso retificar com uma profundidade de corte mínima até que a superfície não apresentasse mais essas irregularidades. Três faces (duas peças) foram trabalhadas para obter uma superfície diferente das anteriores. Os degraus foram feitos conforme a Figura 4.5, retirando de dois terços do comprimento da peça uma profundidade de 20 μm e, dentro destes dois terços, um terço foi retirado mais 20 μm , ficando assim com 40 μm . Pretendeu-se com essas peças ter quase todas as profundidades de corte ao passar o rebolo com 10 μm abaixo da superfície inferior, totalizando 50 μm na superior.




Figura 4.5 – Corpo de prova em degrau.

4.3.2 Ajuste da Retificadora

Para ajustar a velocidade tangencial da retificadora em $V_w = 0,044$ m/s utilizou-se um tacômetro digital da Lutron, modelo DT-2235B, o qual indicou a velocidade tangencial em metros por minuto. O tacômetro possui uma pequena polia esférica emborrachada, para garantir atrito com o corpo a se testar, que encaixa em sua ponta. Essa peça possui uma relação constante que transforma o deslocamento em uma rotação correta de seu eixo. Colocando-se a ponta do tacômetro em um ponto móvel como na Figura 4.6, mediu-se a velocidade tangencial da mesa da retificadora e, através do botão de ajuste da velocidade de

deslocamento da mesa alterou-se a velocidade até atingir o valor desejado. O operador deve ter bastante sensibilidade para alterar a velocidade, pois ela é regulada internamente pela pressão de uma bomba de óleo, sutil a qualquer variação. Assim, o ajuste da velocidade tangencial da mesa estava completo quando o *display* mostrou 2,64 m/min.



Figura 4.6 – Ajuste da velocidade tangencial da mesa com tacômetro (V_w)

O fluido de corte, que serve para refrigerar o corpo de prova durante a retificação, segundo a Indústria Microquímica, deve ter uma proporção de 4% de óleo emulsificante. Foi usado o óleo da Shell, tipo DMS 3200 F-1, dissolvido em água. Para acertar a concentração, foi utilizado um Refratômetro N-1E da Atago, Figura 4.7, que mede a quantidade de óleo através da refração da luz incidente na lente de medição. Ele mede 0% Brix para a água, por meio de uma coluna branca que aparece no seu visor. Caso não apareça a linha no zero, deve-se ajustá-lo por meio de um pequeno parafuso de calibração. Caso seja colocado óleo puro na lente o aparelho mostra 30% Brix por ser o calor máximo que a coluna pode mostrar.



Figura 4.7 – Refratômetro

Basta colocar, depois de calibrado o zero, a amostra da emulsão sobre a lente e fechar sua tampa. Caso fique menor que 4%, deve-se adicionar óleo emulsificante até completar essa proporção. Como o reservatório de fluido de corte é muito grande, deve-se fazer a bomba do fluido bambeá-lo até sua completa diluição.

O inversor de frequência, CFW-02 de 7,5 cv da WEG, controla a velocidade da ferramenta de corte V_s , que é a velocidade tangencial do rebole sobre a peça.

4.3.3 Dressagem

Para afiar o rebolo de óxido de alumínio, foi necessário fazer a operação de dressagem (Figura 4.8). Antes da dressagem, deve-se levar o dressador (Figura 4.9) ao projetor de perfil e fazer a medição da largura de afiação do dressador, b_d .



Figura 4.8 - Operação de dressagem





Figura 4.9 - Dressador posicionado no projeto de perfil



Manípulos de precisão micrométrica

Figura 4.10 – Projetor de perfil usado para medição da largura da ponta do dressador (b_d)

O projetor de perfil da Nikon, modelo 6C, que se encontra no LUA, Laboratório de Usinagem por Abrasão da Unesp-Bauru, amplia a superfície da ponta de diamante do dressador em 1000 vezes. A Figura 20 mostra o dressador no momento da medição.

Para o controle da dressagem após um determinado ensaio, o rebolo era dressado por passes de 40 μm de profundidade, até que toda camada escura que representava o empastamento fosse retirada. O dressador era retirado e colocado no projetor de perfis, onde com a ajuda de duas linhas que cruzam o centro do painel, pode-se medir o tamanho de sua ponta em micrometros, conforme a Figura 4.11.




Figura 4.11 – Esquema utilizado para medição da largura da ponta do dressador

Para a medição correta deve-se colocar o dressador com uma marca no seu corpo em uma posição pré-definida, pois, caso fosse girado o dressador na base, que tem seu corpo cilíndrico, a largura de atuação do dressador, b_d , seria visivelmente diferente sendo preciso compensar a velocidade na dressagem. O projetor possui manivelas vertical e horizontal que desloca a peça. Esse deslocamento deve ser medido absolutamente, gerando assim o valor da largura do dressador b_d . A ponta do dressador no cruzamento central das duas linhas do painel. Aprofunda-se 40 μm da peça na horizontal, que é a profundidade de dressagem utilizada, e através da manivela vertical mede-se o deslocamento. Com o valor de b_d conhecido é possível calcular a frequência que deve ser usada para gerar a velocidade de dressagem necessária à manutenção do grau de recobrimento constante, através da equação 14.

$$t_d = \frac{L_r U_d 60}{n b_d} \quad (\text{Eq. 14})$$

onde,

t_d : tempo de atuação do dressador em segundos

L_r : 40,22 mm → largura do rebolo Norton – ART-FE 38A80-PVH (paquímetro)

$U_d = b_d/S_d$: 5,0 → grau de recobrimento de dressagem (ver Equação 3)

$n = 1799$ rpm → rotação do rebolo (tacômetro) - inversor à 60Hz

$b_d = 1,535$ mm → largura de atuação do dressador (projetor de perfil)

Sabendo que t_d pode ser obtido pela transformação da simples relação entre deslocamento e tempo, se conhecida, a velocidade de dressagem, temos pela equação 15 que:

$$t_d = \frac{L_r}{V_d} \quad (\text{Eq. 15})$$

V_d é a velocidade de dressagem.

Portanto, com a variação de frequência do inversor, e utilizando o tacômetro, similiar ao feito com a velocidade da mesa, chega-se a um tempo de dressagem capaz de manter igual

o valor do grau de recobrimento. Após medir o b_d , aplica-se a Equação 16 e obtém a velocidade de deslocamento do dressador pela superfície do rebolo.

4.4 MEDIÇÃO DE MICRODUREZA

Os testes de microdureza foram realizados na Faculdade de Odontologia da USP de Bauru, no Laboratório de Materiais Dentários. Estes testes consistiram em medir a microdureza ao longo da superfície da peça, a fim de que se pudesse conhecer melhor o comportamento da transformação metalúrgica do material quando houve ocorrência de queima. Esse tipo de ensaio, junto com as medidas de rugosidade e inspeção visual, auxilia as informações condizentes sobre a integridade da peça, facilitando sobremaneira as comparações do processamento digital dos sinais de emissão acústica, e assim, ajudando a encontrar a melhor ferramenta para a detecção da queima no processo de retificação. As medidas foram realizadas em um aparelho da marca Otto Wolpert-Werke, tipo M-Testor, Baujahr, 1962, Figura 4.12, onde se utilizou a escala Vickers para a medição da rugosidade por ter sido essa a mais indicada ao tipo de metal e dureza envolvida. O peso utilizado foi de 100 gramas e o espaçamento entre os pontos ao longo da peça foi de aproximadamente 10 mm.



Figura 4.12 – Detalhes do equipamento de medição de microdureza

O método Brinell de microdureza consiste em uma punção que é pressionada com uma certa força sobre o material a ser testado. Essa punção tem seu formato padronizado que varia a grandeza sensivelmente, dependendo do material utilizado. Existem dois formatos para o método Brinell de medição de microdureza, Vickers, com unidade em Hv (Hardness Vickers), e Knoop, com unidade em Hk (Hardness Knoop). Sobre uma base põe-se o peso P , em

gramas ou em Newton, necessário para fazer a força constante sobre o material. Empurra-se a alavanca de indentação e marca-se a peça com o formato Vicker ou Knoop. Dependendo se o material for muito macio ou muito duro, tal indentação vai penetrar mais ou menos, respectivamente. Através do seu visor, gira-se o avanço até que a barra de referência '0' posicione-se no início da indentação. Mede-se o valor referência através da linha horizontal nos números posicionados na periferia do visor. Gira-se novamente o avanço até que a barra de referência posicione-se no final da indentação. Mede-se novamente o valor dos números da periferia pela linha horizontal. A diferença é o valor d , desejado. Pela Equação 16 ou através de uma tabela, pode-se determinar a relação de microdureza do material estudado. Estes valores têm constante direta para a transformação na unidade g/mm^2 .

$$H_v = \frac{0,189P}{d^2} \quad \text{ou} \quad H_k = \frac{14,2P}{d^2} \quad (\text{Eq. 16})$$

Para minimizar erros nas medições, devido à variação da microdureza pelo material, realizaram-se três medidas na mesma faixa perpendicular da peça, conforme Figura 4.13.




Figura 4.13 – Subdivisões na peça para medir Microdureza

5 RESULTADOS E DISCUSSÕES

Durante os ensaios na retificadora foram coletados os dados que foram processados no LADAPS, Laboratório de Aquisição de Dados e Processamento de Sinais na UNESP-Bauru, que geraram os gráficos com os parâmetros estatísticos para análise de queima. Após os ensaios na retificadora, foram realizados os testes de visualização a olho nu e informatizada das peças, por meio de fotografias e um *software* quantizador de queima pela análise de cores desenvolvido por Dotto (2004).

5.1 VISUALIZAÇÃO DAS PEÇAS

A Tabela 5.1 mostra as faces das peças usinadas as quais visualmente se pode observar que a coloração vai do cinza claro, que caracteriza uma peça sem queima, até o preto, que caracteriza uma queima severa, dependendo do grau de queima ocorrido (Malkin, 1989). As peças foram fotografadas digitalmente e então, posteriormente, analisadas pelo *software* de “Quantificação de Queima” (Dotto, 2004) que analisa a contraste, pixel a pixel.

Tabela 5.1 – Fotografias das peças usinadas na retificadora plana

Prof. a[μ m]	COLORAÇÃO DAS PEÇAS USINADAS		
	C1	C2	C3
10,0			
22,5			
30,0			
35,0			
40,0			
50,0			
Degraus			

Para fotografá-las foi necessário um ambiente relativamente escuro, abrindo a objetiva da câmera digital Sony CyberShot DSC-S60 em 1,0 segundo. Retiraram-se todos objetos reluzentes próximos às peças e temporizou a fotografia, estando a câmera apoiada sobre um pedestal para que não houvesse trepidações enquanto a objetiva estivesse aberta. Isso é necessário devido às superfícies metálicas serem tratadas como espelhos por equipamentos digitalizadores, e que, se tivesse grande quantidade de luz no ambiente, iriam refleti-las à objetiva, desfocando a fotografia.

Após recortar as fotos e tratá-las em *software* de edição de imagem, as imagens foram abertas uma a uma no “Quantificador de Queima”, mostrado na Figura 5.1, que fez sua quantificação do padrão de cor adotado e que geraram a Tabela 5.2.



Figura 5.1 - *Software* de Quantificação de Queima (Dotto, 2004)

A “Barra de Cores” permite a modificação do limiar entre as situações de queima e não queima, entretanto, como já existe um padrão de pré-definido, não é necessária a sua alteração por meio desta barra. Ao se pressionar o botão “Analisar”, a análise dos dados é iniciada. A Figura 5.2 mostra os resultados obtidos nessa análise. Pode-se notar que as cores da foto foram modificadas. Após processamento, as regiões da peça que se encontram na cor azul refletem a situação da não queima.



Figura 5.2 – Exemplo de Resultados Obtidos do *Software* de Quantificação de Queima

A região em vermelho representa as partes da peça que sofreram algum tipo de queima, seja leve, média ou severa. A cor amarela representa regiões que são desconsideradas, ou seja, como a peça não é perfeitamente regular, as partes que não pertencem à peça (fundo) durante o processo feito pelo *software* ficam na cor branca a qual é desconsiderada durante os cálculos estatísticos. Pode-se observar que se tem 5 campos principais e três específicos para a situação de queima. Os campos “Área Desconsiderada”, “Região Sem Queima” e “Região com Queima” mostram a porcentagem da peça que se enquadra em cada uma dessas situações, ou seja, se o campo “Região Com Queima” tem valor igual a 25,24%, sendo que, aproximadamente 25% da peça tem algum tipo de queima. O campo “TOTAL” retorna à

soma das porcentagens dos campos acima que deve ser sempre 100%. A caracterização e classificação da queima foram feitas visualmente durante a usinagem. De acordo com a coloração das peças após cada passe da retificadora a superfície da peça foi classificada com sem queima, queima leve, queima média e queima severa conforme Tabela 5.2.

Para esses experimentos, as condições do tipo de aço e rebolo, características de dressagem, velocidades, fluido de corte e máquina retificadora, onde há uma faixa para a profundidade de corte em que a queima começa a ocorrer. A Tabela 5.2 mostra que, a partir da peça L2, (35 μm), a profundidade de corte sobre as superfícies usinadas, apresentou valores de queima em quase toda a sua totalidade, com valores entre 78,98% a 96,54%.

Tabela 5.2 – Quantificação das Cores das peças ensaiadas

Profundidade de Corte 'a' (μm)	Código da Peça	Região Sem Queima (%)	Região Com Queima (%)	Análise da Área de Queima		
				Queima Leve (%)	Queima Média (%)	Queima Severa (%)
10,0	C1	99,28	0,72	0,75	0,06	99,19
10,0	C2	99,21	0,79	4,65	0,81	94,53
10,0	C3	99,25	0,75	4,91	0,27	94,81
22,5	H1	99,29	0,71	0,06	0,00	99,94
22,5	H2	99,24	0,76	4,49	1,64	93,88
22,5	H3	90,28	9,72	91,99	0,59	7,42
30,0	K1	98,77	1,23	17,13	7,32	75,55
30,0	K2	99,28	0,72	2,93	0,50	96,57
30,0	K3	98,63	1,37	46,79	0,12	53,09
35,0	L1	97,48	2,52	70,81	0,00	29,19
35,0	L2	21,02	78,98	11,42	24,70	63,88
35,0	L3	6,84	93,16	9,05	11,61	79,34
40,0	M1	20,42	79,58	27,64	42,58	29,77
40,0	M2	7,55	92,45	6,38	13,51	80,11
40,0	M3	9,96	90,04	15,41	36,12	48,47
50,0	O1	20,26	79,74	19,32	40,53	40,15
50,0	O2	3,46	96,54	3,73	15,75	80,52
50,0	O3	4,10	95,90	5,36	21,32	73,31
Degrau	DG1	72,43	27,57	18,26	57,88	23,86
Degrau	DG2	85,60	14,40	58,50	30,59	10,91
Degrau	DG3	64,24	35,76	6,94	14,23	78,83

**Q
U
E
I
M
A**

Obs: Toda área desconsiderada foi adotada como 0 (zero).

A peça L3, Figura 5.3, apresentou uma região de queima de 93,16%, onde esta região foi subdividida entre queima severa, 79,34%, queima média, 11,61% e queima leve, 9,05%.

A peça M2, com uma região de queima de 92,45%, onde 80,11% com queima severa, 13,51% queima média e 6,38% queima leve. A peça O2, com uma região de queima de 96,54%, onde 80,52% de queima severa, 15,75% de queima média e 3,73% de queima leve. A peça O3, 95,90% da região da queima, apresentou 73,31% de queima severa, 21,32% queima média e 5,36% queima leve. Sendo assim, a profundidade de corte é fundamentalmente importante para se determinar as condições de queima na retificação. Vale ressaltar que, na superfície da peça, a queima ocorre com mais intensidade e não gradativa para o aço ABNT 1020. Para a distribuição da quantificação entre queima leve, queima média ou queima severa, dentro da região classificada como ocorrência de queima, não houve linearidade nos resultados conforme Figura 5.3.




Figura 5.3 – Gráfico de Quantificação das cores das peças ensaiadas acima de 35 µm

Conforme a Figura 5.4, quando não houve queima, peça H2 que apresentou uma região sem queima de 99,24%, mas houve uma região de queima de 0,76%, onde 93,88% de queima severa. Para a peça K1 com uma região sem queima de 98,77%, com uma região de queima de 1,23% , sendo considerada 75,55% de queima severa.

A temperatura da peça vai se elevando e propagando junto ao rebolo, aquecendo a superfície e acumulando calor para que ocorra a queima. Como o fenômeno de queima na retificação é muito sensível, e, as peças, por mais minuciosas que tenham sido elaboradas,

sempre há um erro devido à precisão dos equipamentos (paralaxe) e ao próprio material na formação de suas grades cristalinas do metal, além do material ter um relaxamento nessa grade ao sofrer um processo industrial.

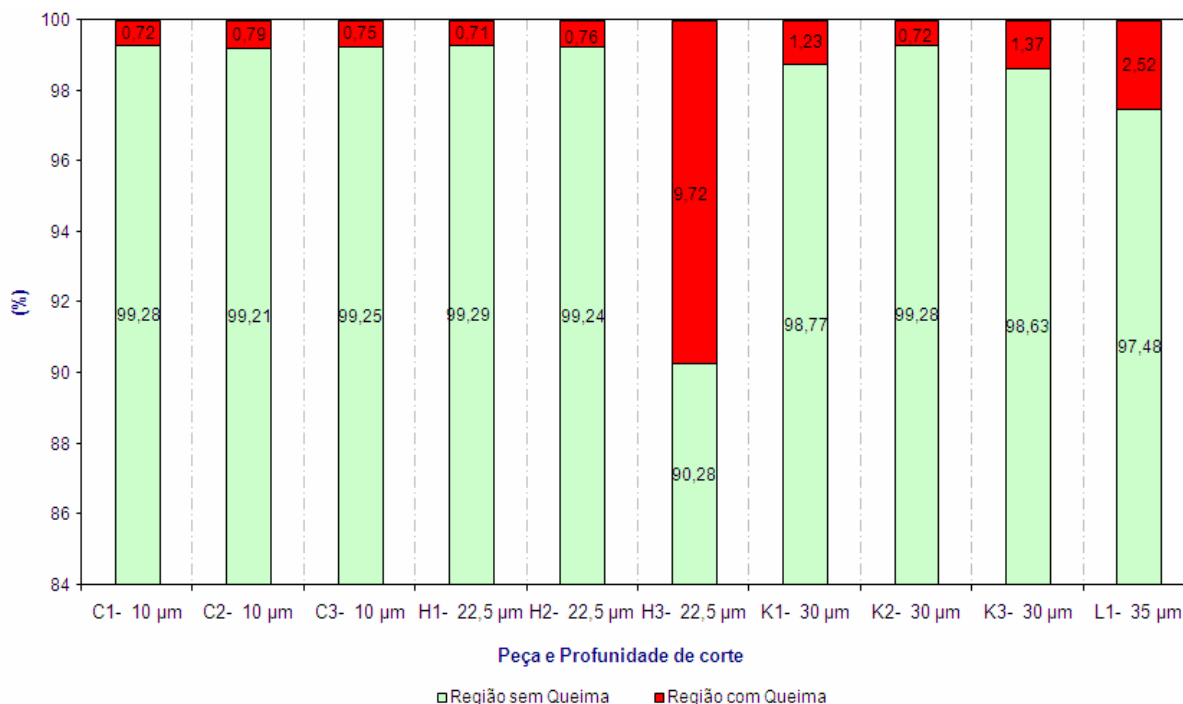


Figura 5.4 – Gráfico de Quantificação das cores das peças ensaiadas até 35 µm.

A Tabela 5.3 mostra todas as peças identificadas como queima pelo padrão de cor do *software* e pela análise visual das peças. Algumas peças, H3 (91,99% de queima leve dentro de 9,72% de região de queima), K3 (53,09% de queima severa dentro da região de queima de 1,37%) e L1 (70,81% de queima leve dentro da região de queima de 2,52%) aparecem pequenas regiões que foram identificadas como queima leve devido ao *software* não conseguir distinguir se a coloração estava ou não dentro desta região para o padrão de cor utilizado. Essas variações se devem às condições de iluminação e de curvas cromatográficas que o *software* não consegue classificar por ser apenas um classificador dos três níveis dependentes e muito sensíveis do padrão de cor adotado, para o aço ABNT 1020, entretanto gera um bom parâmetro para o percentual de queima de uma superfície retificada.

Tabela 5.3 – Análise do Padrão de Cor

Peça a[μ m]	1	2	3
10 μ m C	 Sem Queima	 Sem Queima	 Sem Queima
22,5 μ m H	 Sem Queima	 Sem Queima	 Faixa de Queima Leve Sem Queima: total Queima Leve: 30-80mm (faixa central) Queima Média: - Queima Severa: -
30 μ m K	 Sem Queima	 Sem Queima Sem Queima: total Queima Leve: - Queima Média: - Queima Severa: -	 Sem Queima Sem Queima: total Queima Leve: - Queima Média: - Queima Severa: -
35 μ m L	 Sem Queima Sem Queima: total Queima Leve: - Queima Média: - Queima Severa: -	 Queima Severa Sem Queima: 0-10mm Queima Leve: 10-15mm Queima Média: 15-27mm Queima Severa: total	 Queima Severa Sem Queima: - Queima Leve: 0-14mm Queima Média: 14-24mm Queima Severa: total
40 μ m M	 Queima Severa Sem Queima: 0-10 e 145-152mm Queima Leve: 10-20 e 130-145mm Queima Média: 110-130mm Queima Severa: 20-110mm	 Queima Severa Sem Queima: 0-8mm Queima Leve: - Queima Média: 8-17mm Queima Severa: total	 Queima Severa Sem Queima: 0-6mm Queima Leve: 6-13mm Queima Média: - Queima Severa: total
50 μ m O	 Queima Severa Sem Queima: 0-8mm Queima Leve: 8-20mm Queima Média: 20-30 e 140-152mm Queima Severa: 30-140mm	 Queima Severa Sem Queima: 0-3mm Queima Leve: - Queima Média: 130-152mm Queima Severa: total	 Queima Severa Sem Queima: 0-3mm Queima Leve: - Queima Média: 3-4mm Queima Severa: total
DG	 Queima Severa Sem Queima: 0-1mm Queima Leve: 42-50mm Queima Média: - Queima Severa: 1-42mm (Degrau)	 Queima Severa Sem Queima: 0-96mm Queima Leve: - Queima Média: - Queima Severa: 96-152 (Degrau)	 Queima Leve Sem Queima: 0-107mm Queima Leve: 107-152mm Queima Média: - Queima Severa: -

Obs: Tomando como origem da peça, todas elas foram medidas com um paquímetro referenciando cada comprimento da peça por tipo de queima.

5.2 ANÁLISE DE MICRODUREZA

Outra etapa após os ensaios experimentais de retificação foi medir a microdureza Vickers (g/mm^2). Realizando os ensaios conforme o item 4.4, pode-se traçar o perfil de microdureza ao longo da peça, em três dimensões, para cada peça ensaiada, vistos da Figura 5.5 à Figura 5.10.

Calculando-se os valores sobre cada faixa perpendicular da peça, obtém-se uma média dos valores de microdureza e seus respectivos desvios-padrões, que idealmente deveriam ser zero.

Os valores médios para cada face podem ser observados na Tabela 5.4. Destas médias, tem-se a média de microdureza para cada profundidade de corte “ a ”, também representados na Tabela 5.4 e esboçadas na Figura 5.11.

Os desvios-padrões para cada profundidade de corte “ a ” ao longo das faces também foram mostrados na mesma tabela, mas não puderam ser representados devido à dificuldade de visualização que geraria no gráfico.

A Figura 5.12 é a visualização gráfica das médias totais de microdureza, em toda a passada, para cada profundidade de corte “ a ” e seu respectivo desvio-padrão. Foi realizado o mesmo procedimento para os degraus, ou seja, medido três vezes para cada faixa da peça e calculada sua média de microdureza e também seu respectivo desvio-padrão, cujo resultado está esboçado na Figura 5.13.

Tabela 5.4 – Microdureza (g/mm²) medida nas secções de cada corpo.

Secção	1	2	3	4	5	6	7	8	9	10	11	12	13	14	Total
Peça	10,0 µm														
C1	215,7	231,2	197,3	205,3	222,6	227,9	176,5	189,0	172,4	181,4	197,7	182,1	178,2	170,6	
C2	177,8	237,6	234,5	205,5	222,2	171,9	201,0	217,8	155,4	210,9	193,0	148,9	164,3	196,0	
C3	93,1	93,1	139,6	156,0	178,9	203,9	200,0	159,9	168,4	157,4	124,1	176,9	126,6	146,7	
Média	162,2	187,3	190,5	188,9	207,9	201,2	192,5	188,9	165,4	183,2	171,6	169,3	156,3	171,1	181,2
Desvio	62,8	81,6	47,8	28,5	25,1	28,1	13,9	28,9	8,9	26,8	41,2	17,9	26,7	24,6	44,6
	22,5 µm														
H1	178,2	177,8	197,3	149,6	160,6	168,3	161,5	187,3	189,4	190,9	188,3	171,3	184,3	178,2	
H2	185,4	201,7	186,5	184,3	215,7	177,5	194,2	173,8	185,1	175,1	198,9	159,7	174,6	185,8	
H3	148,6	177,8	143,1	132,7	134,9	170,6	159,0	168,8	159,9	151,6	173,9	194,2	135,4	185,1	
Média	170,7	185,8	175,6	155,6	170,4	172,1	171,6	176,6	178,1	172,5	187,0	175,1	164,8	183,0	174,2
Desvio	19,5	13,8	28,7	26,3	41,3	4,8	19,7	9,6	15,9	19,7	12,6	17,6	25,9	4,2	27,8
	30,0 µm														
K1	164,0	185,8	178,2	194,1	168,3	185,4	192,7	146,7	220,0	154,4	175,1	159,9	148,9	150,9	
K2	164,8	149,1	164,3	163,7	141,0	205,8	193,4	164,0	208,8	189,4	175,9	149,1	132,2	170,6	
K3	157,7	193,4	198,2	167,0	173,9	171,2	174,2	163,7	194,2	189,8	185,8	181,4	178,9	167,0	
Média	162,2	176,1	180,2	174,9	161,0	187,5	186,7	158,1	207,7	177,9	179,0	163,5	153,3	162,8	173,6
Desvio	3,9	23,7	17,0	16,7	17,6	17,4	10,9	9,9	12,9	20,3	5,9	16,5	23,7	10,5	27,0
	35µm														
L1	222,2	192,7	209,5	210,9	207,4	157,9	187,8	177,8	220,4	167,0	190,8	134,9	136,0	164,0	
L2	295,3	335,0	422,3	350,0	297,7	378,0	385,3	378,3	393,0	422,7	394,3	392,0	348,7	334,3	
L3	294,3	297,3	295,7	418,7	420,0	374,7	341,3	397,7	403,7	345,3	385,0	373,3	395,0	383,7	
Média	270,6	275,0	309,2	326,5	308,3	303,5	304,8	317,9	339,0	311,7	323,4	300,1	293,2	294,0	305,5
Desvio	42,0	73,7	107,1	105,9	106,7	126,1	103,7	121,7	102,9	131,1	114,9	143,3	138,1	115,3	100,9
	40,0 µm														
M1	243,8	402,1	277,0	254,7	283,4	270,3	277,0	267,4	270,3	340,1	373,5	295,3	287,0	417,4	
M2	216,7	338,2	286,0	183,4	285,1	406,5	422,4	353,3	415,7	393,6	424,5	435,3	298,0	265,6	
M3	276,9	373,9	325,5	315,6	332,6	354,3	262,5	384,7	297,7	306,9	309,0	351,9	397,2	343,5	
Média	245,8	371,4	296,2	251,2	300,3	343,7	320,6	335,2	327,9	346,8	369,0	360,8	327,4	342,2	324,2
Desvio	30,2	32,0	25,8	66,2	27,9	68,7	88,4	60,7	77,3	43,8	57,9	70,5	60,7	75,9	96,9
	50,0 µm														
O1	325,1	313,5	326,5	425,9	324,1	338,0	317,9	297,7	351,9	359,3	276,6	256,4	366,8	291,0	
O2	293,1	277,5	307,2	336,0	315,6	323,1	293,1	336,0	338,9	344,9	397,0	346,4	351,9	289,2	
O3	296,7	264,0	317,3	334,3	337,7	304,7	349,3	345,3	376,7	381,3	388,3	338,7	340,7	470,3	
Média	305,0	285,0	317,0	365,4	325,8	321,9	320,1	326,3	355,8	361,8	354,0	313,8	353,1	350,2	332,5
Desvio	17,6	25,6	9,6	52,4	11,1	16,7	28,2	25,3	19,2	18,4	67,1	49,9	13,1	104,0	63,7
	Degrau														
DG1	198,3	213,7	204,7	250,3	218,3	252,0	224,7	208,7	234,0	208,0	307,7	337,3	269,0	326,7	
DG2	215,3	209,7	242,0	228,0	227,7	219,3	234,7	229,0	240,7	365,0	381,0	303,3	321,7	351,0	
DG3	189,7	167,6	149,6	192,7	221,0	163,5	174,2	190,8	238,3	250,7	245,2	325,1	244,9	263,8	

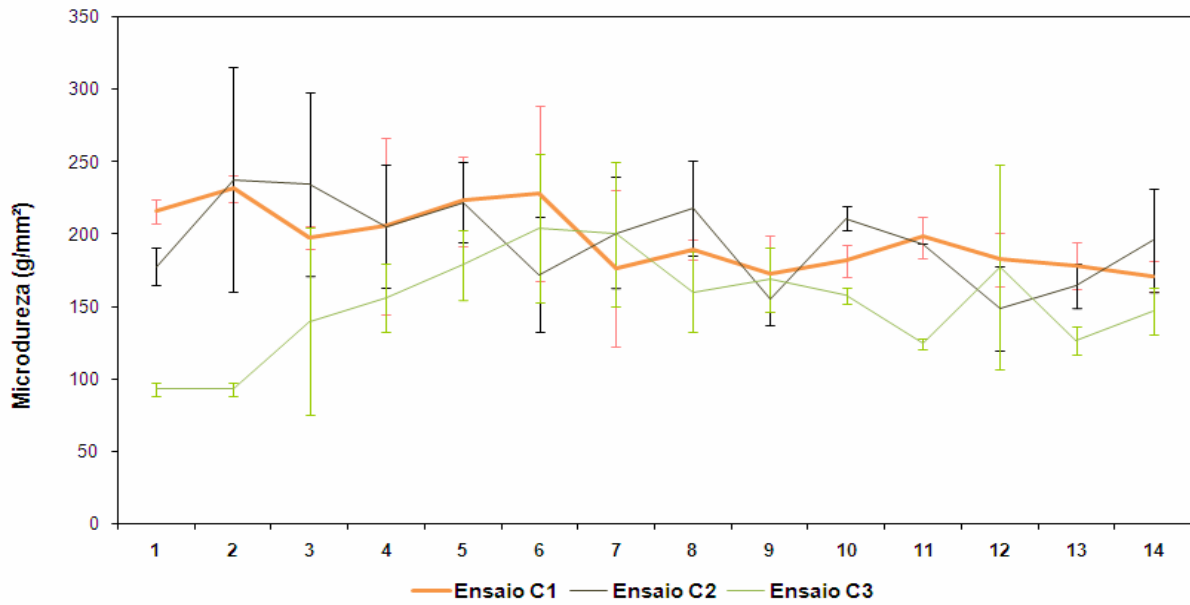


Figura 5.5 – Média e desvios-padrões da microdureza das peças $a = 10 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça)

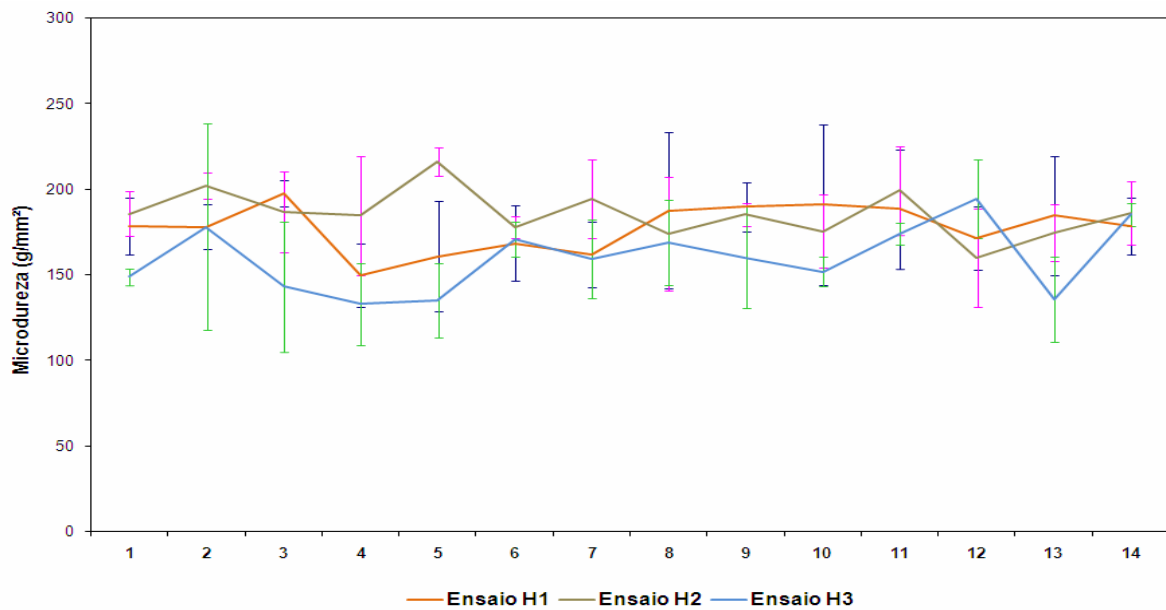


Figura 5.6 – Média e desvios-padrões da microdureza das peças $a = 22,5 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça)




Figura 5.7 – Média e desvios-padrões da microdureza das peças $a = 30 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça)




Figura 5.8 – Média e desvios-padrões da microdureza das peças $a = 35 \mu\text{m}$ (eixo horizontal em número de divisão (secção) ao longo da peça)




Figura 5.9 – Média e desvios-padrões da microdureza das peças a = 40 μm (eixo horizontal em número de divisão (secção) ao longo da peça)




Figura 5.10 – Média e desvios-padrões da microdureza das peças a = 50 μm (eixo horizontal em número de divisão (secção) ao longo da peça)

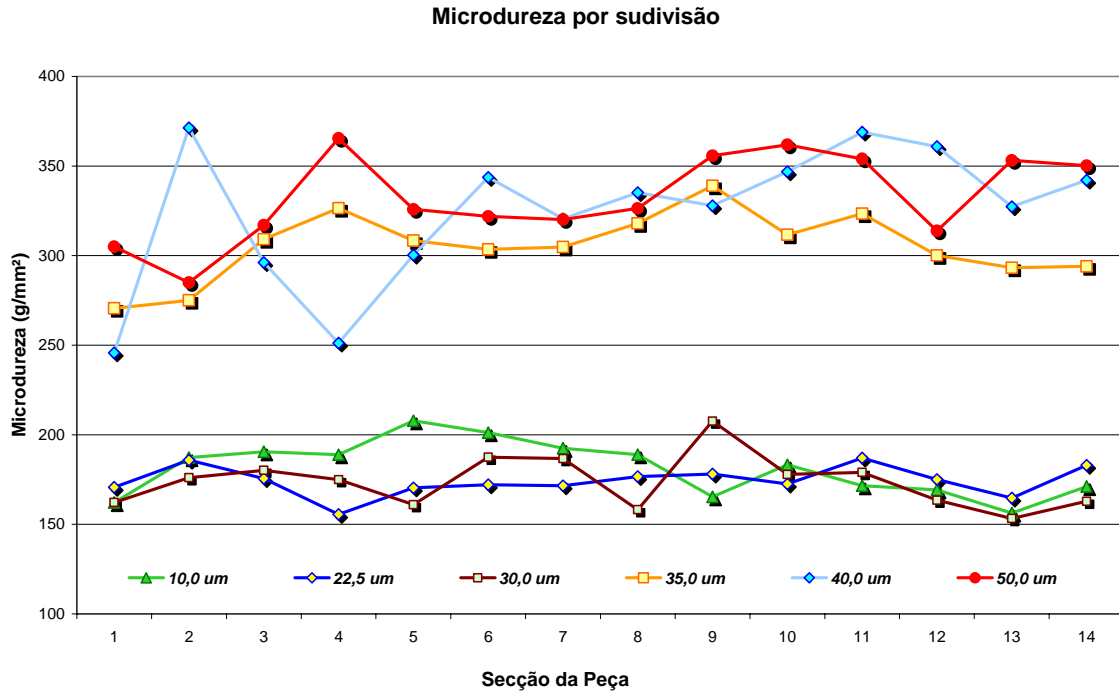


Figura 5.11 – Média de microdureza para cada profundidade de corte e ao longo do comprimento da peça. Eixo horizontal é o número de divisão das medidas ao longo da peça

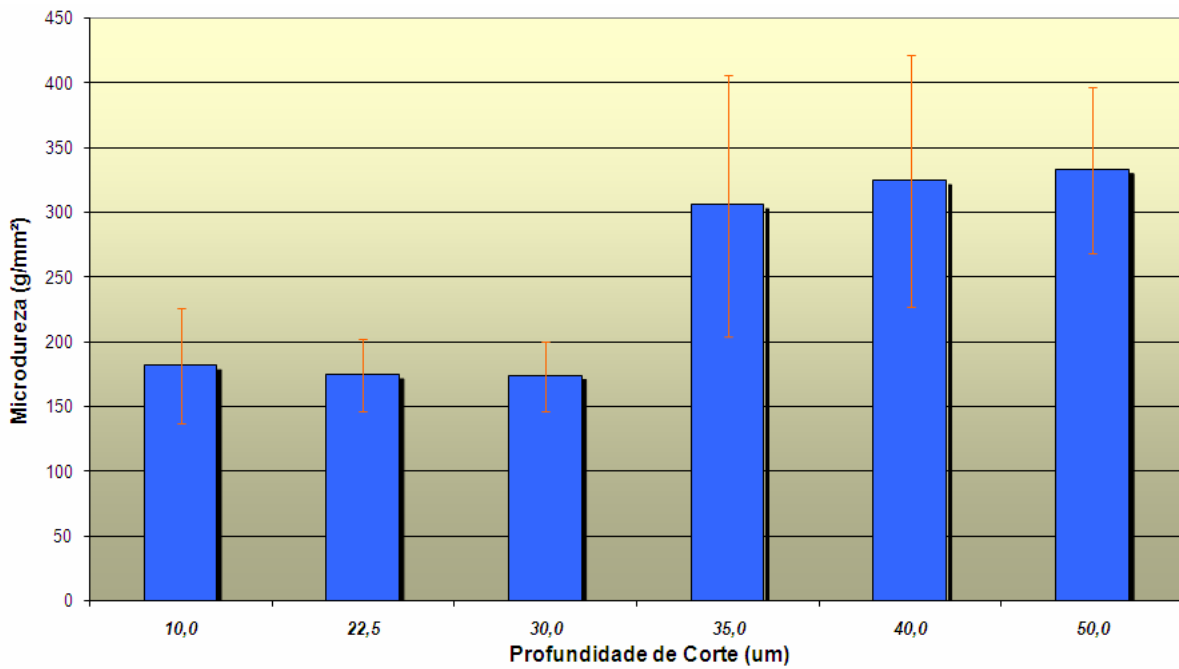


Figura 5.12 – Média totais de microdureza das passadas para cada profundidade de corte e o seu respectivo desvio padrão

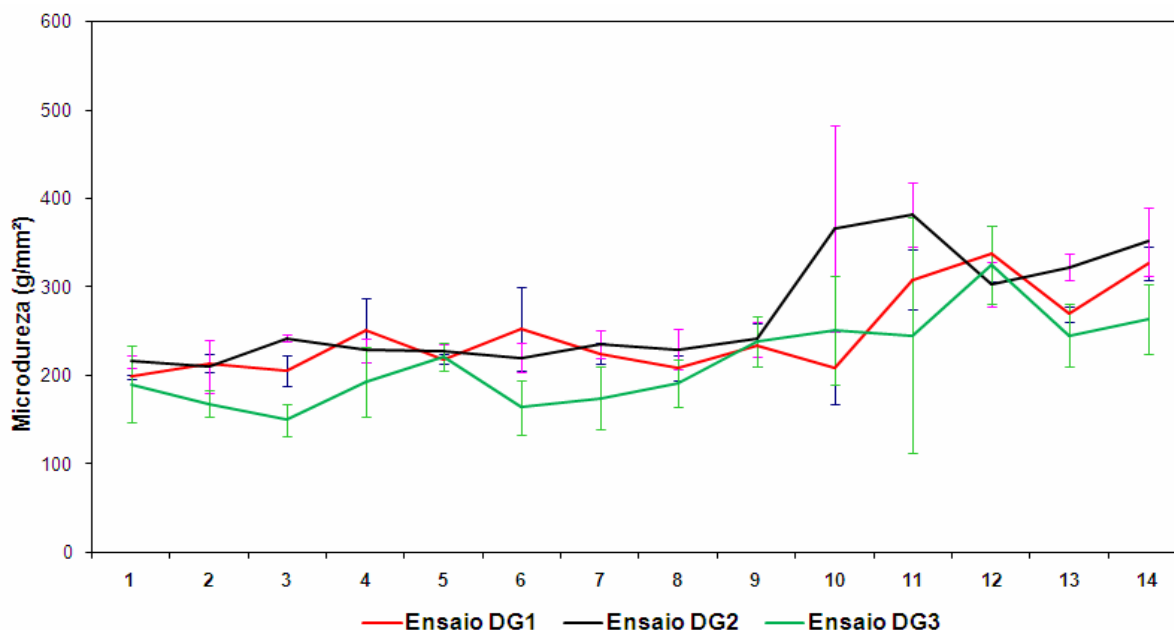


Figura 5.13 – Média e desvios-padrões da microdureza dos degraus (eixo horizontal em número de divisão (secção) ao longo da peça)

Ao identificar graficamente a média da microdureza das peças ao longo das peças conforme a Figura 5.8, onde se nota que a peça L1 não apresentou queima para as condições dos ensaios, o que não ocorreu nas peças L2 e L3. Para as peças C1, C2 e C3 da Figura 5.5, as peças H1, H2 e H3 da Figura 5.6 e as peças K1, K2 e K3 da Figura 5.7, onde suas médias totais de microdureza para a profundidade de corte ficaram muito próximas, 181,20; 174,20 e 173,60 g/mm² respectivamente. Porém, para as peças L1, L2 e L3 da Figura 5.8, as peças M1, M2 e M3 da Figura 5.9 e as peças O1, O2 e O3 da Figura 5.10, onde suas médias totais de microdureza, 305,5; 324,2 e 332,5 em g/mm², respectivas profundidades de corte. Nota-se que a peça L1 não apresentou queima, e que sem ela a média total seria em vez de 305,5 seria de 366,2 g/mm², uma redução de 20% na média total do grupo. Isso é devido a faixa de microdureza de 124,2 g/mm² entre as médias, de quando ocorre e não ocorre a queima entre as peças, observado na Figura 5.11. Somente a média da peça L1 é de 184,2 g/mm², bem próximo às outras peças que não queimaram. Na Figura 5.13 observa-se que o material aumenta sua microdureza somente sobre a área de queima da peça, detalhadamente sobre a peça DG2, que houve queima mais severa em relação às outras, observado na Tabela 5.2, também houve maior microdureza encontrada a partir de 10 μm, ou seja, seu terço final. Assim, confirma-se que quando ocorre a queima, o material sofre um encruamento, endurecendo o aço, devido a têmpera e a conseqüente formação de austenita (ferro γ) na

cristalografia do aço (ver item 3.3). O parâmetro de microdureza é então um bom indicativo da ocorrência de queima no metal. O ideal seria ter um sinal elétrico que gerasse tal parâmetro dinamicamente, porém não pode ser analisado senão por ensaios de microdureza em equipamentos laboratoriais e dividido por etapas. Outro problema seria que, caso conseguisse ser medido a microdureza durante a passagem, não haveria como classificar se a peça iria ou não queimar, pois, ela só indica se houve ou não a queima da passagem após ser concluída.

5.3 RESULTADOS OBTIDOS DO PROCESSAMENTO DOS SINAIS

Os gráficos da Figura 5.14 até a Figura 6.34 apresentam as estatísticas processadas e apresentadas no Capítulo 5 juntamente com os sinais de potência elétrica do motor de acionamento do rebolo.

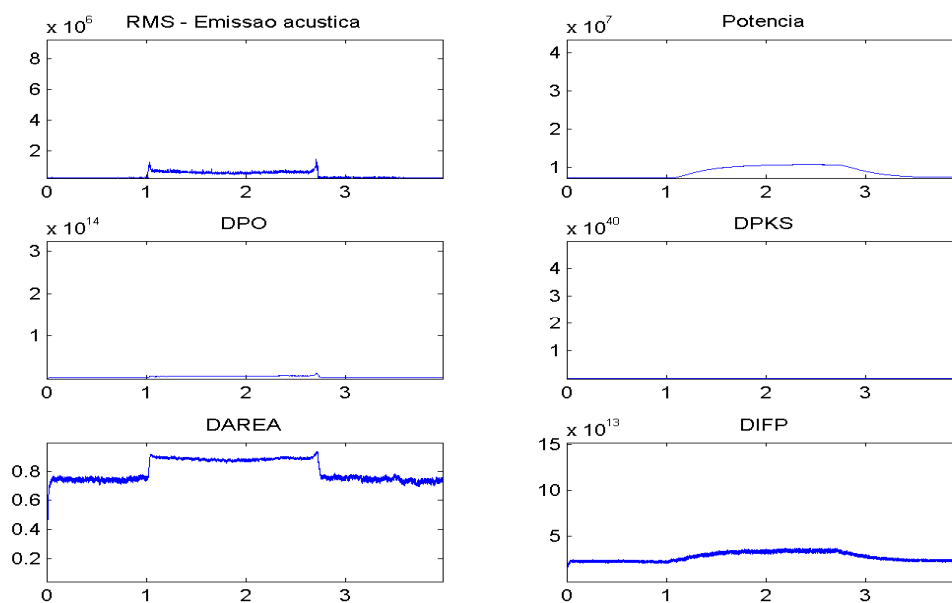


Figura 5.14 – Gráficos das Estatísticas para a peça (C1) → 1ª Amostra para $a = 10,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

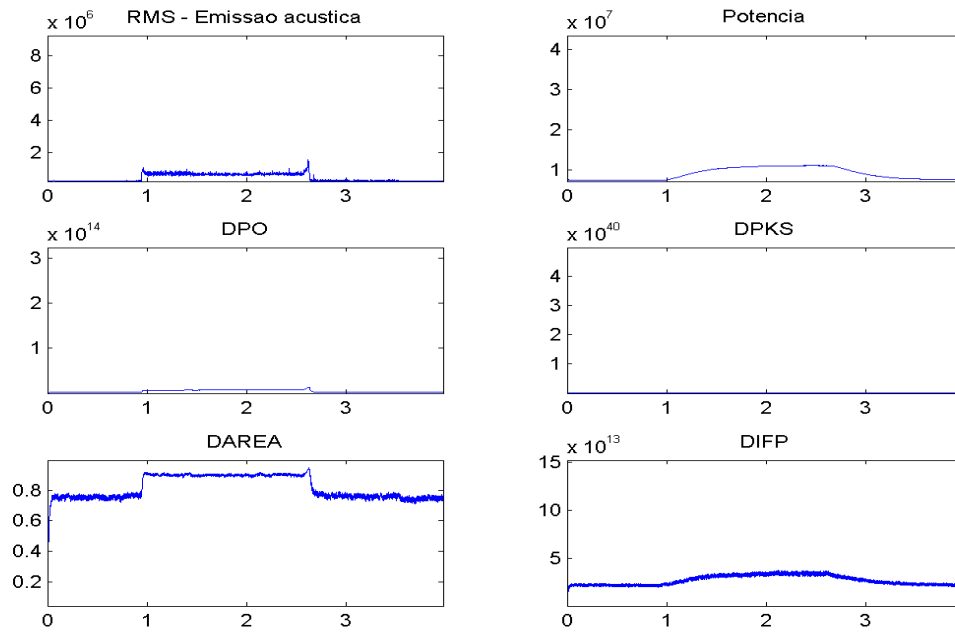


Figura 5.15 – Gráficos das Estatísticas para a peça (C2) → 2ª Amostra para $a = 10,0 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts×K

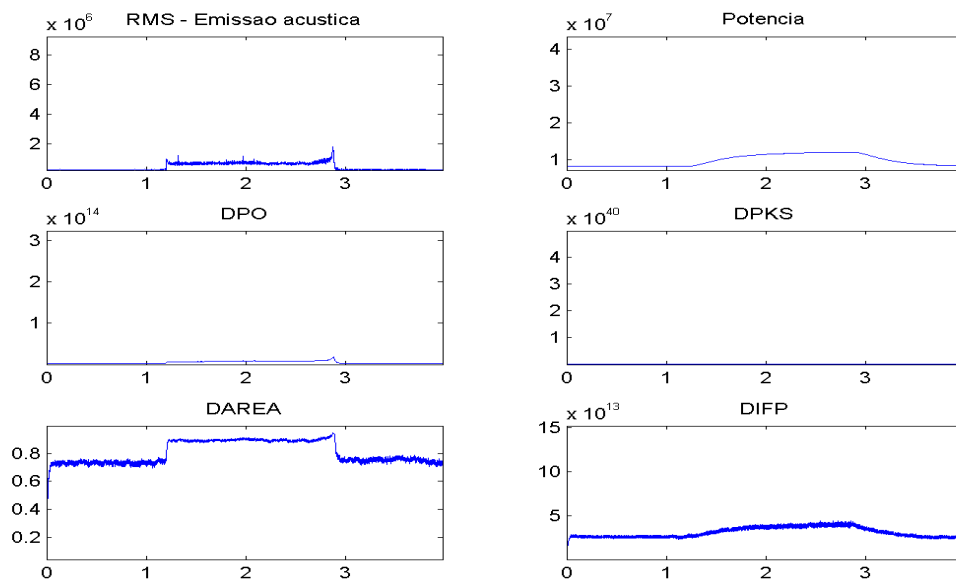


Figura 5.16 – Gráficos das Estatísticas para a peça (C3) → 3ª Amostra para $a = 10,0 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts×K

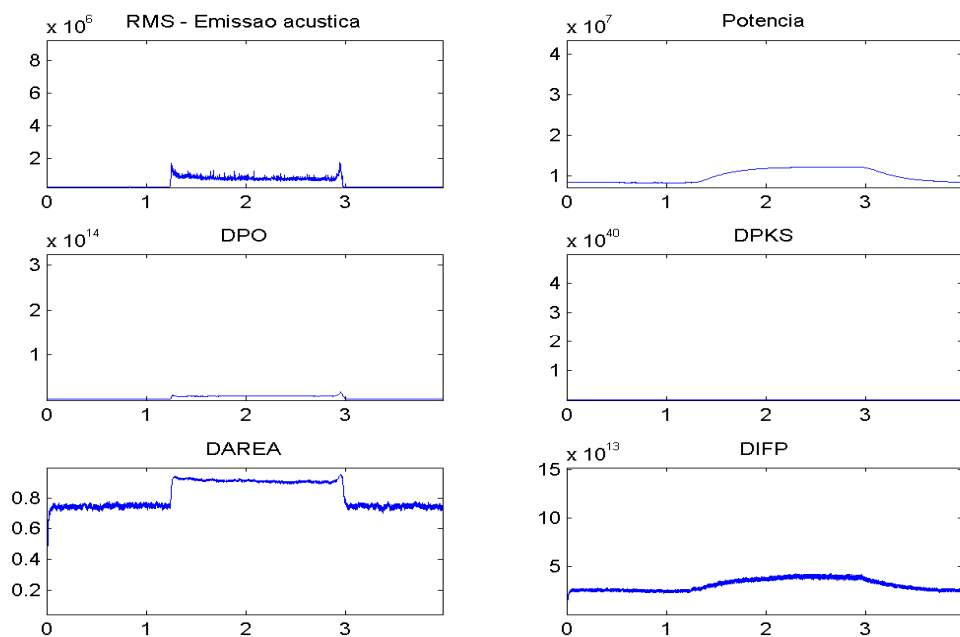


Figura 5.17 – Gráficos das Estatísticas para a peça (H1) → 1ª Amostra para $a = 22,5 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

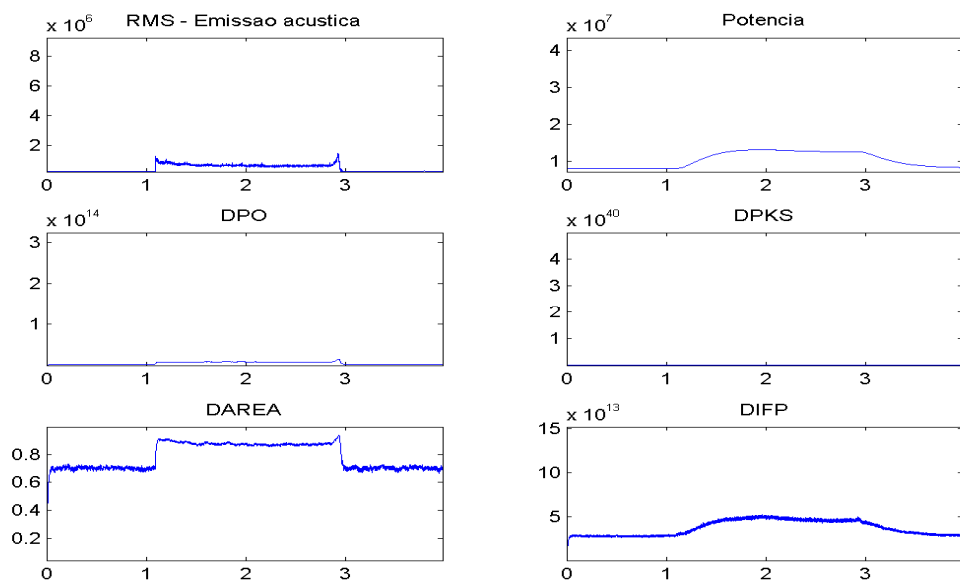


Figura 5.18 – Gráficos das Estatísticas para a peça (H2) → 2ª Amostra para $a = 22,5 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

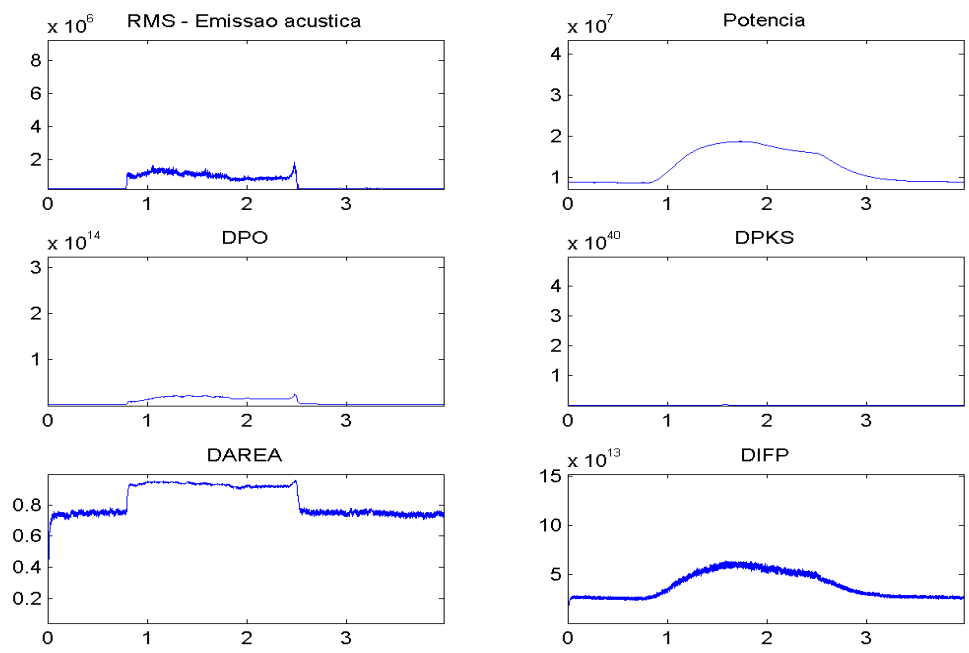


Figura 5.19 – Gráficos das Estatísticas para a peça (H3) → 3ª Amostra para $a = 22,5 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts×K




Figura 5.20 – Gráficos das Estatísticas para a peça (K1) → 1ª Amostra para $a = 30,0 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts×K

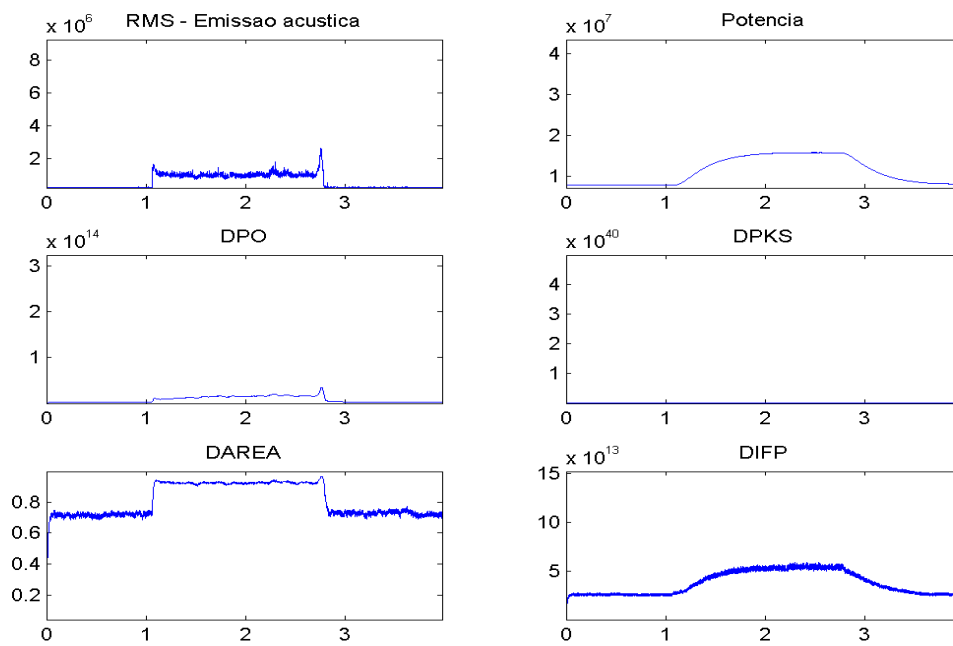


Figura 5.21 – Gráficos das Estatísticas para a peça (K2) → 2ª Amostra para $a = 30,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

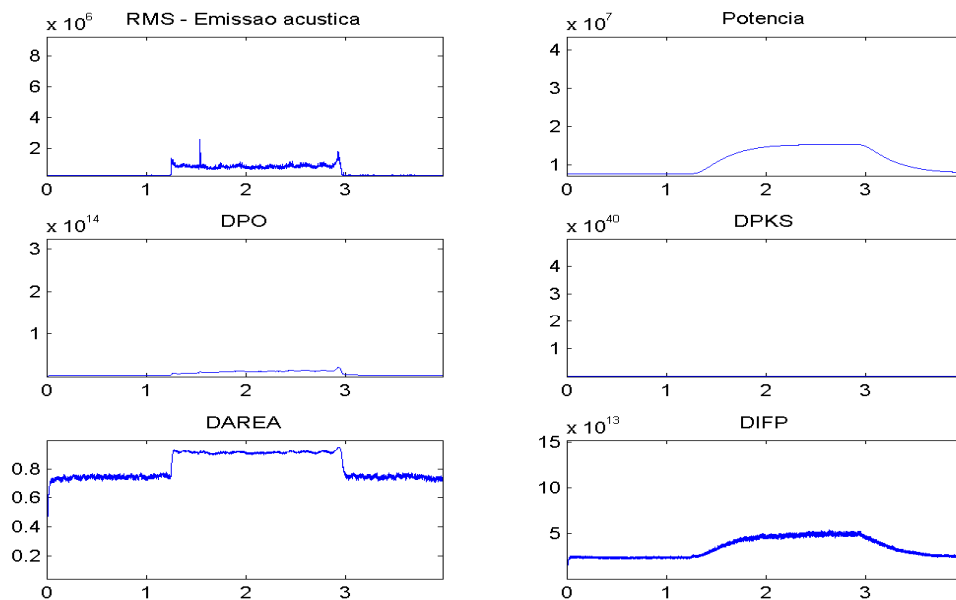


Figura 5.22 – Gráficos das Estatísticas para a peça (K3) → 3ª Amostra para $a = 30,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

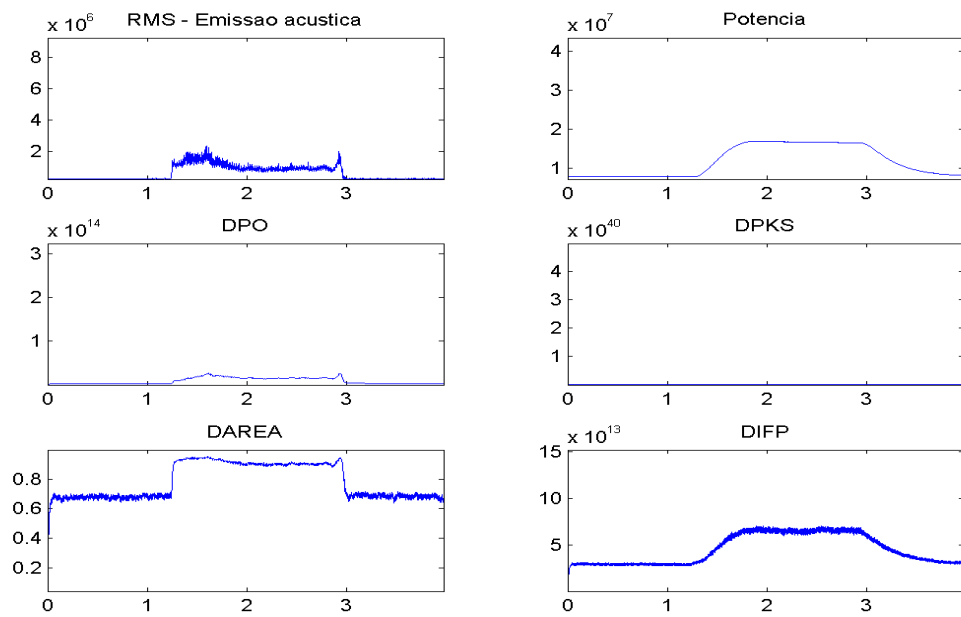


Figura 5.23 – Gráficos das Estatísticas para a peça (L1) → 1ª Amostra para $a = 35,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts×K

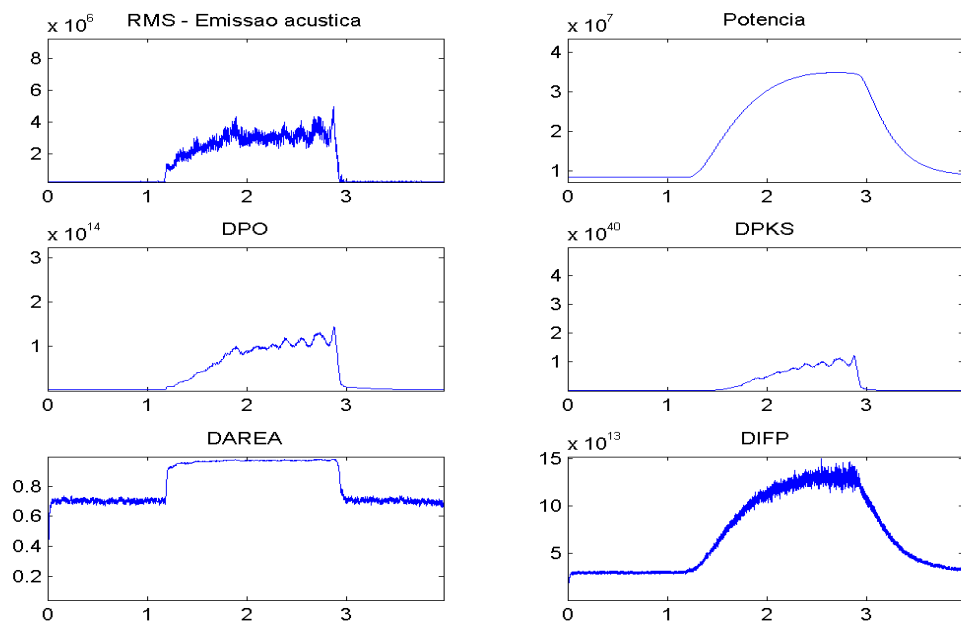


Figura 5.24 – Gráficos das Estatísticas para a peça (L2) → 2ª Amostra para $a = 35,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts×K

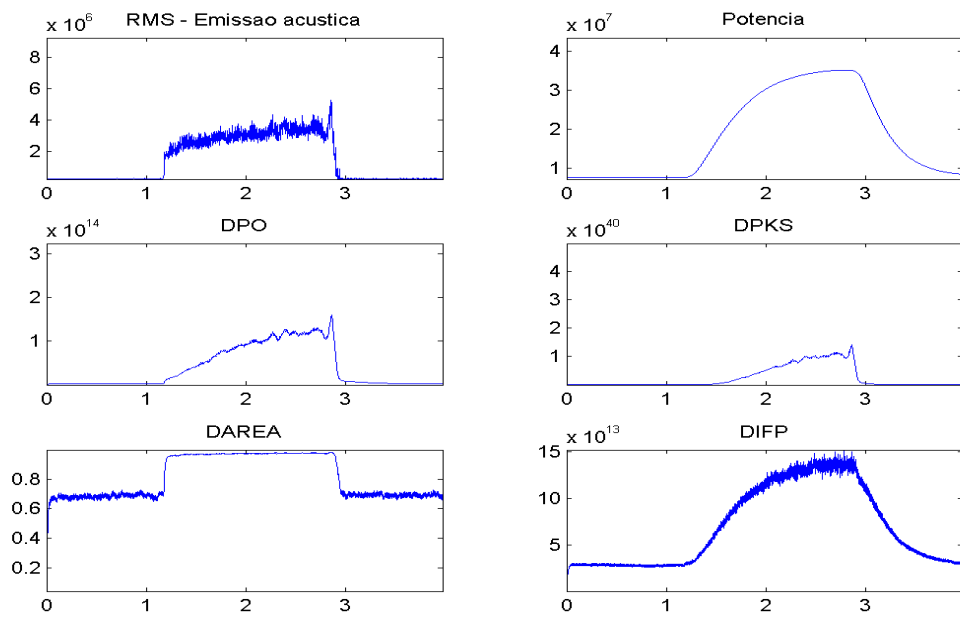


Figura 5.25 – Gráficos das Estatísticas para a peça (L3) → 3ª Amostra para $a = 35,0 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts \times K

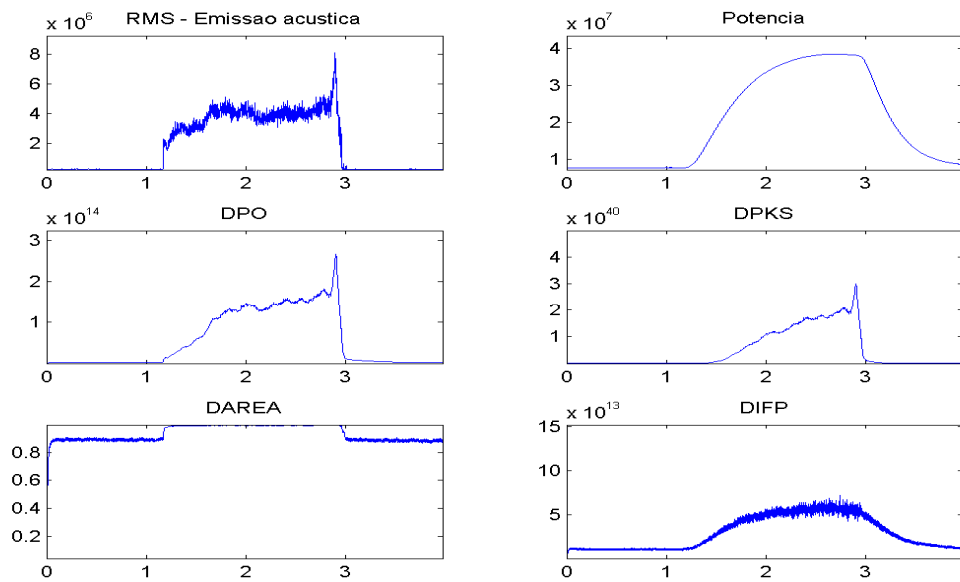


Figura 5.26 – Gráficos das Estatísticas para a peça (M1) → 1ª Amostra para $a = 40,0 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts \times K

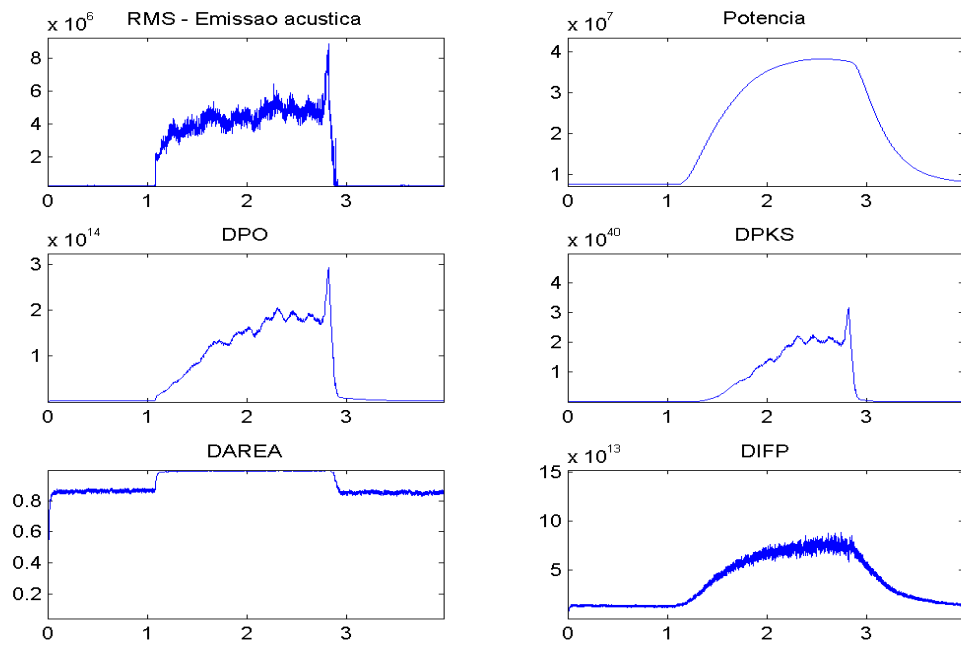


Figura 5.27 – Gráficos das Estatísticas para a peça (M2) → 2ª Amostra para $a = 40,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

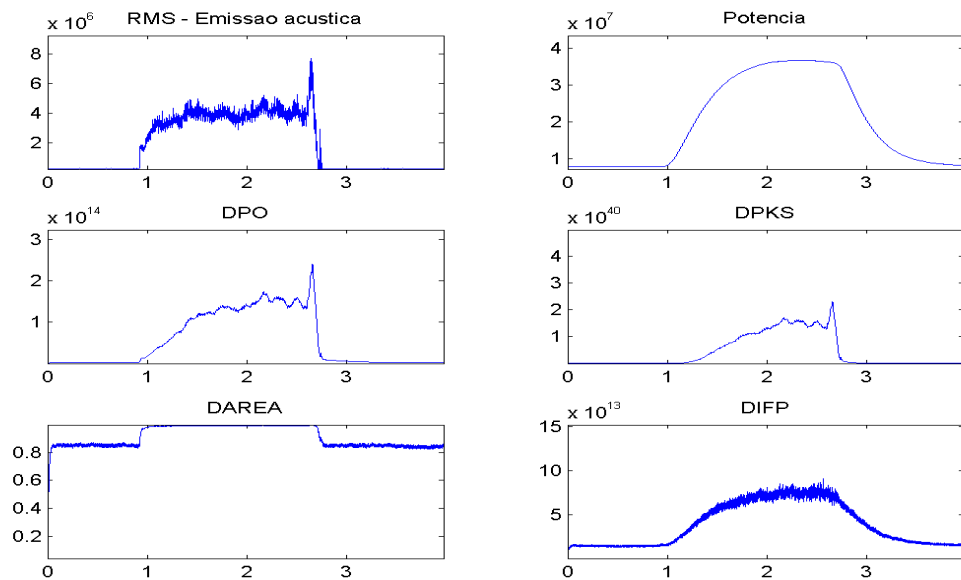


Figura 5.28 – Gráficos das Estatísticas para a peça (M3) → 3ª Amostra para $a = 40,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

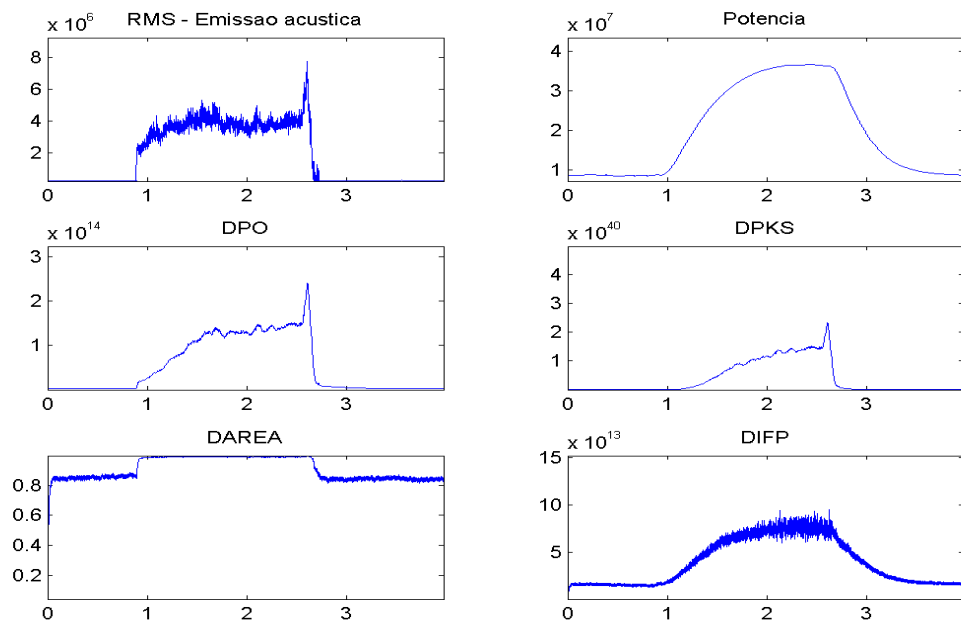


Figura 5.29 – Gráficos das Estatísticas para a peça (O1) → 1ª Amostra para $a = 50,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

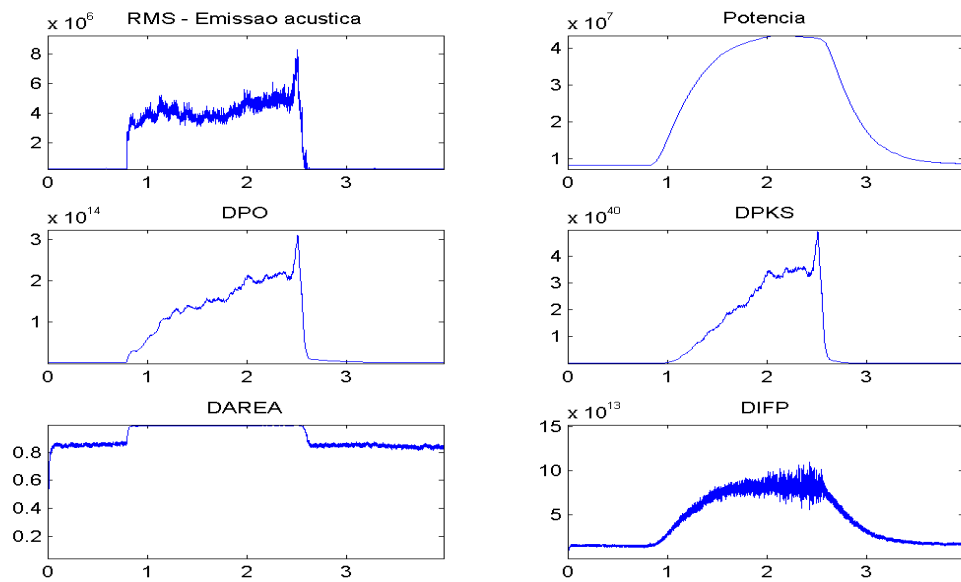


Figura 5.30 – Gráficos das Estatísticas para a peça (O2) → 2ª Amostra para $a = 50,0 \mu\text{m}$; Escala horizontal em segundos; Escala vertical em Volts \times K

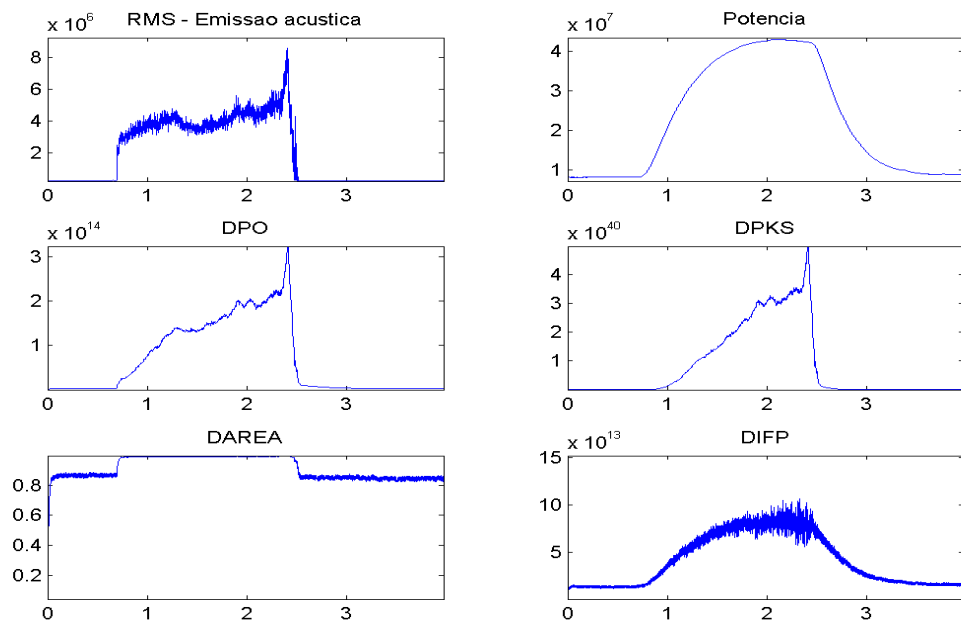


Figura 5.31 – Gráficos das Estatísticas para a peça (O3) → 3ª Amostra para $a = 50,0 \mu\text{m}$;
Escala horizontal em segundos; Escala vertical em Volts×K

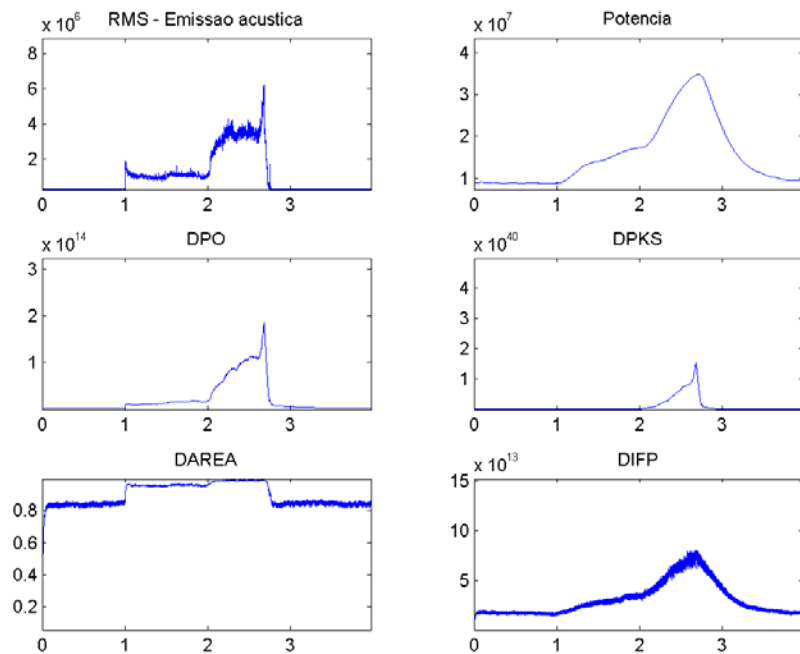


Figura 5.32 – Gráficos das Estatísticas para a peça (DG1) - peça com Degrau
Escala horizontal em segundos; Escala vertical em Volts×K

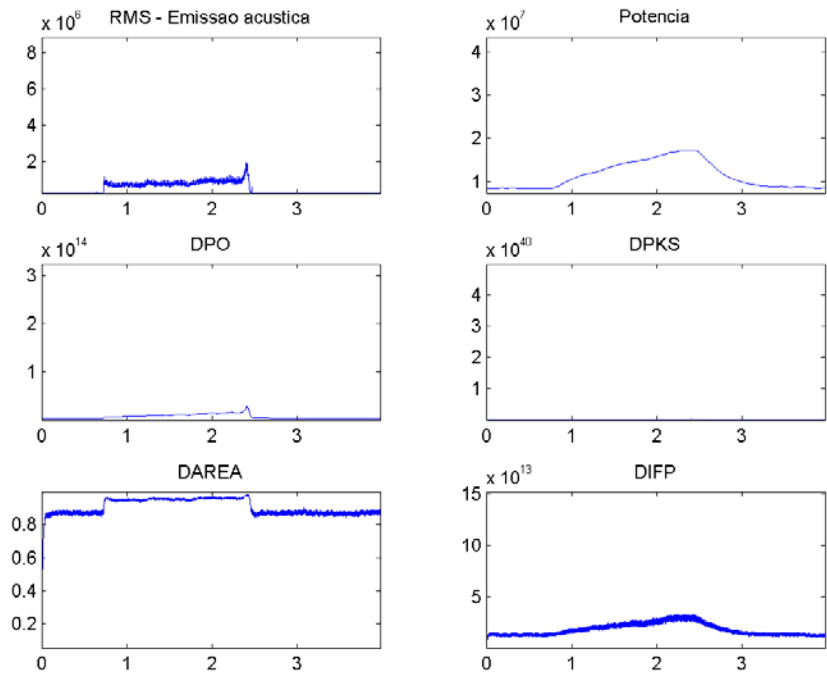


Figura 5.33 – Gráficos das Estatísticas para a peça (DG2) - peça com Degrau
Escala horizontal em segundos; Escala vertical em Volts×K

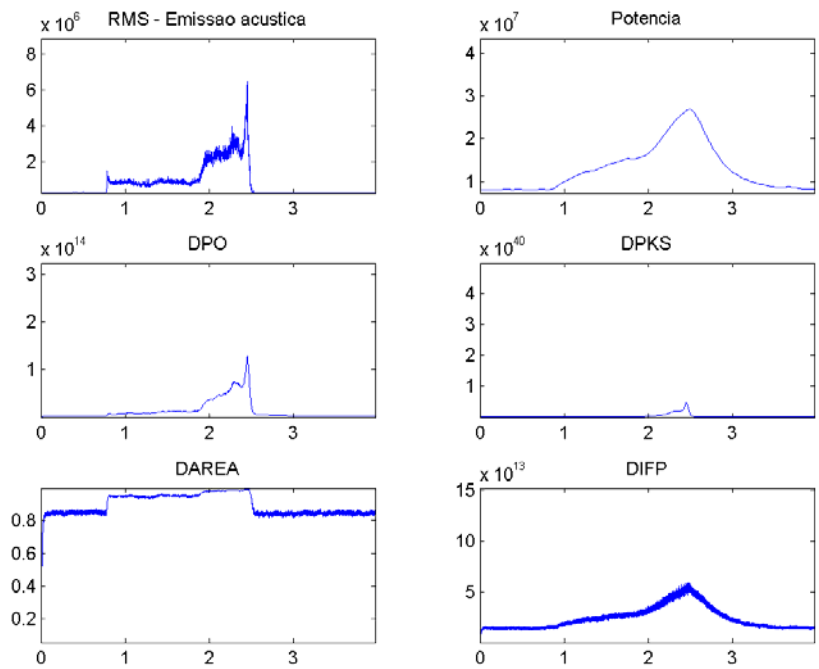


Figura 5.34 – Gráficos das Estatísticas para a peça (DG3) - peça com Degrau
Escala horizontal em segundos; Escala vertical em Volts×K

5.3.1 Análise dos Parâmetros Estatísticos de Queima

5.3.1.1 Emissão Acústica – RMS

Visualizando as médias da emissão acústica da Figura 5.35, observa-se que seus valores permanecem semelhantes até $a = 30 \mu\text{m}$. A partir deste ponto sua média aumenta significativamente, coincidindo com o início da queima das peças ensaiadas.




Figura 5.35 – Valores médios de EA(RMS) para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em $\text{Volts} \times K$

Para as peças com $a = 35 \mu\text{m}$, a média da Emissão Acústica da peça L1 passou de $10,84 \cdot 10^5$ unidades na Figura 5.23, para a média de $27,51 \cdot 10^5$ unidades na peça L2, Figura 5.24, e para a peça L3, a média de $29,63 \cdot 10^5$, Figura 5.25. Observa-se que a peça L1 não queimou, enquanto que as peças L2 e L3 obtiveram queima. Assim, verificou-se que o sinal RMS de emissão acústica é um parâmetro que quantifica a queima na retificação para o metal ABNT 1020, podendo estipular para estas condições de ensaios um limite dinâmico médio de queima de $28 \cdot 10^5$ unidades, onde ocorreu esse valor máximo para as peças L2 e L3 da Figura 5.24 e Figura 5.25 respectivamente, ou um limite de $(27,51+29,63)/2 = 28,57 \cdot 10^5$ unidades para esta média nas passadas. Na Tabela 5.3, observa-se que a peça M1, que obteve queima a partir de 10 mm intensificando a partir de 20 mm, e sua emissão acústica, na Figura 5.28, teve uma elevação em seu gráfico aumentando entre os pontos 1,2 segundos e 1,65 segundos até estabilizar em $43 \cdot 10^5$ unidades, ficando assim com uma média de $37,84 \cdot 10^5$ unidades. A peça M2 obteve queima a partir de 8 mm de contato do rebolo com a peça, obtendo uma média de $42,19 \cdot 10^5$ unidades, na Figura 5.27. A peça M3 teve queima a partir de 6 mm, sendo mais forte a partir de 13 mm, obtendo também uma média $37,40 \cdot 10^5$ unidades, Figura 5.28. Respectivamente, nos gráficos da Figura 5.27 e da Figura 5.28, obtiveram um crescimento logo no início do contato. A peça O1, queimou a partir de 8 mm com severidade com menos de 1 s, a partir de 30 mm, esse crescimento é observado na Figura 5.29. Nas peças O2 e O3 a queima foi imediata, verificada nos gráficos da Figura 5.30 e da Figura 5.31.

5.3.1.2 Potência Elétrica

Outro sinal adquirido na aquisição, a Potência Elétrica do motor do rebolo, variou significativamente com o uso de profundidades de corte menores que $a = 35 \mu\text{m}$ em relação às profundidades maiores, visto na Figura 5.36.




Figura 5.36 – Valores médios de Potência Elétrica para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts \times K

Observando as análises da peça L1, Figura 5.23, em relação às peças L2 e L3, Figura 5.24 e Figura 5.25, o sinal de potência altera-se sensivelmente quando ocorre a queima da peça, com valores respectivamente de $1,30 \cdot 10^7$, $1,85 \cdot 10^7$, $1,93 \cdot 10^7$ unidades, também verificando que a Potência é representativa da queima em uma retificação. O limite de queima para este parâmetro estaria compreendido entre o primeiro e o último valor, ou seja, pode-se estimar $1,63 \cdot 10^7$ unidades. O limite instantâneo pode ser estimado como o máximo valor da potência para a peça em que não houve queima, a peça L1, que é $2,0 \cdot 10^7$ unidades. Porém, os sinais brutos de potência são atrasados no tempo devido às capacitâncias do circuito de medição e inércias do sistema, com seu comportamento de carga quando o rebolo é solicitado e descarga ao sair o rebolo sobre peça. Devido a estes atrasos do sistema, a potência não é um bom parâmetro para a localização da queima na peça, mas é um bom parâmetro para parametrizar toda a passada.

5.3.1.3 DPO

O parâmetro DPO, apresentou variação significativa nos seus valores por passada, conforme Figura 5.37.




Figura 5.37 – Valores médios de DPO para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts \times K

Os valores médios de DPO foram de $6,46.10^{12}$, $11,88.10^{12}$ e $15,14.10^{12}$ unidades, respectivamente às peças C-10 μm , H-22,5 μm e K-30 μm as quais não obtiveram queima, conforme Figura 5.14 à Figura 5.23, e $84,26.10^{12}$, $115,72.10^{12}$ e $141,38.10^{12}$ unidades, respectivamente às peças L-35 μm , M-40 μm e O-50 μm , conforme as Figuras 5.24 a 5.31. Para os valores, como o parâmetro relaciona potência elétrica e emissão acústica, verifica-se na Figura 5.23 e na Figura 5.24 que o parâmetro passou a ser observado significativamente. Porém, o parâmetro DPO obteve melhor resultado, onde se representa à superfície de queima, a partir da Figura 5.24 a 5.31, todas as análises começaram a surgir logo no início do contato do rebolo, crescendo até o fim do processo.

5.3.1.4 DPKS

Neste parâmetro DPKS também verifica valores visíveis a partir do gráfico estatísticos para a peça, Figura 5.24. Em se tratando do sinal médio por passada, Figura 5.38, o parâmetro obteve um bom comportamento, tendo pequena variação antes da queima e crescendo em relação à profundidade de corte.




Figura 5.38 – Valores médios de DPKS para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts \times K

O parâmetro passou de $0,68.10^{38}$ unidades, para todas as peças de $a = 30 \mu\text{m}$, para $24,69.10^{38}$ unidades, para todas as peças de $a = 35 \mu\text{m}$. Para a peça L1, de $a = 35 \mu\text{m}$, ocorreu que o valor ficou em $1,22.10^{38}$ unidades onde não houve queima, e as peças L2 e L3, de $a = 35 \mu\text{m}$, ficaram em $36,25.10^{38}$ e $39,51.10^{38}$ unidades, respectivamente, as quais apresentaram queima. Assim, uma estimativa do limite para este parâmetro estaria no meio desses valores, ou seja, $19,42.10^{38}$ unidades. Observando-se no gráfico da Figura 5.24, um valor estimado para o limite instantâneo de queima para os valores de DPKS seria $2,39.10^{38}$ unidades, uma vez que não há visualização gráfica para quando não ocorre a queima. O parâmetro começou a ter significado a partir do ponto 1,5 s para a Figura 5.26, onde a peça M1 começou a queimar somente a partir de 10 mm, conforme Tabela 5.3. Já para a peça O2, onde obteve queima imediata, o gráfico de DPKS da Figura 5.30, mostra que o valor apareceu ao mesmo tempo que a potência. Porém, não se pode afirmar que o parâmetro utilizado desta forma detecta o início da queima, pois o trabalho que originou tal parâmetro utilizou diversas

passadas até que o rebolo perdesse a afiação e queimasse a peça. Isso é observado na Figura 5.31, onde a peça teve queima no instante que o rebolo tocou a peça e o gráfico apresenta um atraso de resposta em aproximadamente 0,3 s.

5.3.1.5 DIFP

Como o parâmetro DIFP, Equação 06, leva em consideração valores do coeficiente angular α da reta que vai de 0 até o valor máximo do sinal de emissão acústica, dentro da janela, os resultados ficaram muito sensíveis à pequenas variações, amplificando os ruídos do sinal, Figura 5.14 a Figura 5.31. Os valores médios ficaram disformes conforme vistos no gráfico correspondente da Figura 5.39. Com isso o parâmetro não é adequado para a análise de queima.




Figura 5.39 – Valores médios de DIFP para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts \times K

5.3.1.6 DAREA

O parâmetro DAREA, pode ser considerado o mais sensível, pois a situação de queima só pode ser observado como mostra a Figura 5.40, pelas suas médias. Os valores médios dos ensaios sem queima, para as profundidades de 10 μm , 22,5 μm e 30 μm , são 0,88; 0,91 e 0,92 unidades respectivamente e com queima, para as profundidades de 35 μm , 40 μm e 50 μm , são 0,94; 0,98 e 0,99 unidades respectivamente portanto a variação foi muito pequena entre elas. Este parâmetro, conforme as Figuras 5.14 a Figura 5.23, sem queima, é visível notar suas medias estão próximas de 0,905 unidades e com queima, Figura 5.24 a Figura 5.31, próximas de 0,983 unidades, pequena variação antes da queima e depois da queima, uma diferença de 7.86%.




Figura 5.40 – Valores médios de DAREA para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts \times K

Para as peças que não apresentaram queima, C-10 μm , H-22,5 μm e K-30 μm , com suas respectivas média de 0,88; 0,91 e 0,92 unidades, sendo as peças que apresentaram queima severa L-35 μm (L2 e L3), M-40 μm e O-50 μm , com suas respectivas médias, 0,96; 0,99 e 0,99 unidades. Observando a peça L1, de $a = 35 \mu\text{m}$, onde DAREA apresentou uma média de 0,91 unidades a partir de 1,2 s e para as peças L2 e L3, de $a = 35 \mu\text{m}$, 0,96 unidades para 1,2 s, uma diferença de 5,21%. As peças de profundidade de 40 μm e 50 μm observam que as médias permaneceram em 0,99 unidades, com um desvio padrão de 0,010 e 0,014 respectivamente ao redor da media, conforme as Figuras 5.28 a Figura 5.33, portanto bastante sensível à queima severa.

5.3.1.7 Análise dos Degraus

Para as peças em degrau, com exceção à peça (DG2), Figura 5.33 em que o sinal de emissão acústica não se alterou e apesar de aparecer na Tabela 5.2 queima em 14,4% da peça, notou-se que a emissão acústica respondeu imediatamente a solicitação de corte da peça, confirmando sua resposta dinâmica ao sistema, conforme Figura 5.41.




Figura 5.41 – Valores médios de EA(RMS) para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts×K

Na potência elétrica houve crescimento quando o rebolo era solicitado em uma profundidade maior, Figura 5.42, mas também se observa o retardo na resposta do sinal.




Figura 5.42 – Valores médios de Potência Elétrica para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts×K

Nos cálculos das peças com degrau, notou-se que os parâmetros DPO e DIFP obtiveram respostas relativamente maiores que os outros parâmetros, identificando a região de queima da peça, Figura 5.43. Na Figura 5.32 e Figura 5.34, os sinais de emissão acústica destacaram bem a região de elevação da peça. Assim, os parâmetros DPO e DIFP, os quais foram bem relacionados à detecção de queima, elevaram seus valores nesta região. Mais atentamente, DPO ficou mais nítido que os outros desde o início da queima.




Figura 5.43 – Valores médios de DPO, DPKS, DAREA e DIFP para os ensaios realizados
Escala horizontal em μm – profundidade de corte; Escala vertical em Volts×K

5.4 REDES NEURAIS ARTIFICIAIS - RNA

5.4.1 Modelamento das Redes Neurais Artificiais

As redes neurais usadas neste trabalho foram construídas com a utilização do “software” MATLAB 6.5, que contem específicas funções e pacotes matemáticos que permitem a elaboração da rede, com relativa simplicidade. Diversas estruturas foram testadas, além das quatro diferentes estatísticas dos sinais, para obter a configuração que fornecesse melhores resultados ao tipo de sinal utilizado. Com todos os dados medidos através dos ensaios de usinagem, pôde-se iniciar o modelamento das redes neurais. Para esta pesquisa, optou-se pelas redes neurais chamadas de *Multi Layer Perceptrons - backpropagation* (MLP), ou *Perceptrons* de múltiplas camadas com treinamento *backpropagation*, pelas ótimas características que este modelo de RNA possui em relação ao foco desta pesquisa. Esta etapa

do estudo visa mostrar os procedimentos realizados na investigação do melhor conjunto de dados de entrada para que a RNA obtenha um resultado satisfatório na predição. A estrutura esquemática dos ensaios, conforme Figura 5.44, mostra o modelamento da RNA neste trabalho. Estas estruturas serão vistas com maior detalhamento a seguir, contudo, deve-se dizer que a diferença está na quantidade de dados de entrada (neurônios de entrada) e no tamanho da base de dados. A Figura 5.45 mostra esta divisão das variáveis utilizadas como valores de entrada e saída da RNA.

5.4.2 Dados de Entrada para Rede Neural Artificial (RNA)

Neste trabalho, dos ensaios de usinagem foram obtidas as seguintes variáveis:

- ❖ Sinal da Potência do motor de acionamento (**Pot**);
- ❖ Sinal de Emissão Acústica (**EA**);
- ❖ Profundidade de corte (**a**);
- ❖ Parâmetros derivados do Sinal de Potência e EA: **DPO, DPKS, DIFP e DAREA**;

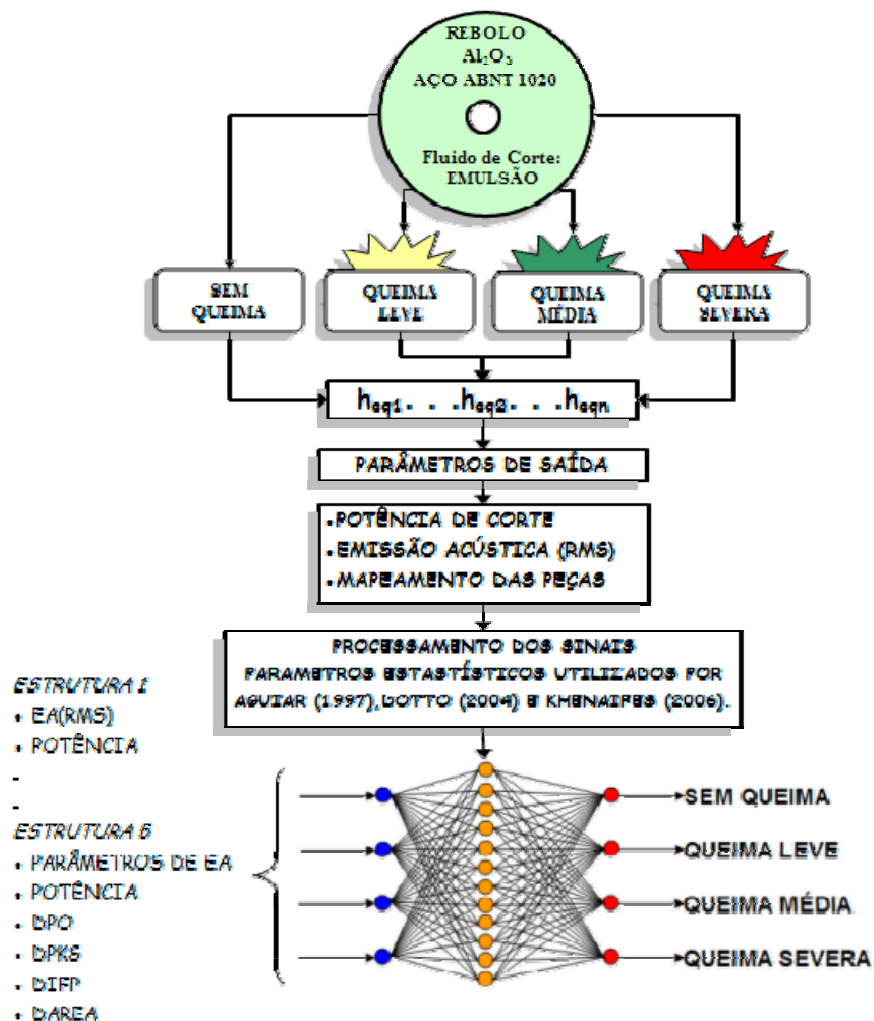


Figura 5.44 - Estrutura esquemática dos ensaios

Os dados de entrada foram dispostos em estruturas, nos quais cada um apresenta conjuntos diferentes de dados. Isto foi feito para determinar o grau de importância de algumas destas variáveis na predição. A Figura 5.45 apresenta as cinco estruturas de dados de entrada escolhidos para o presente trabalho.




Figura 5.45 – Estruturas de dados de entrada da RNA

Nas estruturas, a RNA é alimentada com os vetores, de aproximadamente 3890 pontos, cujo conjunto de pontos se consegue detalhar as regiões de “Queima Leve”, “Queima Severa” e “Sem Queima”. No entanto este conjunto de pontos também será utilizado pela RNA para treinamento e validação. Para as cinco estruturas o dado de saída foi a ocorrência de, sem queima, queima leve e queima severa, representada pelo conjunto de saída “0 0 1”, “0 1 0” e “1 0 0” respectivamente. A queima média foi considerada igual à queima severa pelos dados se aproximarem muito dos níveis da emissão acústica.

5.4.3 Treinamento das RNA's

Nos ensaios definitivos foram utilizados 6 peças, com 3 tipos de profundidade, resultando em 18 ensaios, onde foram escolhidos 5 ensaios que possuíam os níveis de queimas bem definidos. A partir disto, foram escolhidos pontos de cada ensaio que caracterizavam melhores os níveis da queima para o treinamento das RNA's. O restante dos ensaios foram utilizados para validação da rede.

5.4.4 Parâmetros da RNA

Os parâmetros utilizados nos treinamentos das RNA's, para a taxa de aprendizagem, o momento e o número de neurônios da camada oculta foram definidos em 0,6; 0,5 e 11 respectivamente, onde estes valores representam a intensidade da mudança de peso em cada época, após tentativas com valores diversos.

Os testes das RNA's utilizaram os seguintes comandos:

- newff: comando para uso da rede neural MLP backpropagation;
- logsig: função de ativação dos neurônios da camada interna e de saída;

- `traingd`: algoritmo de treinamento gradiente de descida;
- `premnmx`: todos os dados utilizados no treinamento das RNA's foram normalizados;
- `tramnmx`: todos os dados utilizados na validação das RNA's também foram normalizados a partir da normalização aplicada aos dados do treinamento;
- `train`: comando de treinamento da RNA; e
- `sim`: comando de simulação da RNA.

5.4.5 Resultado do treinamento das RNA's

A experiência adquirida com o trabalho fixou-se o valor de 20.000 épocas de treinamento, que representam a quantidade de realimentação da rede com os valores de saída. Verificado que os valores acima de 20.000 épocas começavam a “viciar” a rede neural, tornando-a insensível ao aprendizado e prejudicando sua atuação na classificação da queima com novas entradas.

5.4.6 Resultados das RNA's

Os gráficos que serão apresentados a seguir seguem uma legenda de cor:

- amarelo para classificação “Sem Queima”;
- verde para “Queima Leve”;
- vermelho para “Queima Severa”.

Os gráficos da esquerda, representa o comportamento da queima, através dos sinais de cada estrutura com seu respectivo ensaio e profundidade. As cores representam esse comportamento. Os gráficos da direita, são apresentados pela identificação e classificação da queima pela RNA, também pelo seu respectivo ensaio e profundidade.

5.4.6.1 RNA 1: EA-RMS, Potência e Profundidade de corte (Estrutura I)

Nas Figuras 5.46 a 5.63, são mostrados os resultados obtidos pela estrutura I juntamente com as imagens das peças ensaiadas. Cor amarela (sem queima), cor verde (queima leve) e cor vermelha (queima severa).




Figura 5.46 – Resultado da RNA (C1) para profundidade de 10,0 μ m.
A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.47 – Resultado da RNA (C2) para profundidade de 10,0 μ m.
A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.48 – Resultado da RNA (C3) para profundidade de 10,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.49 – Resultado da RNA (H1) para profundidade de 22,5 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.50 – Resultado da RNA (H2) para profundidade de 22,5 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K

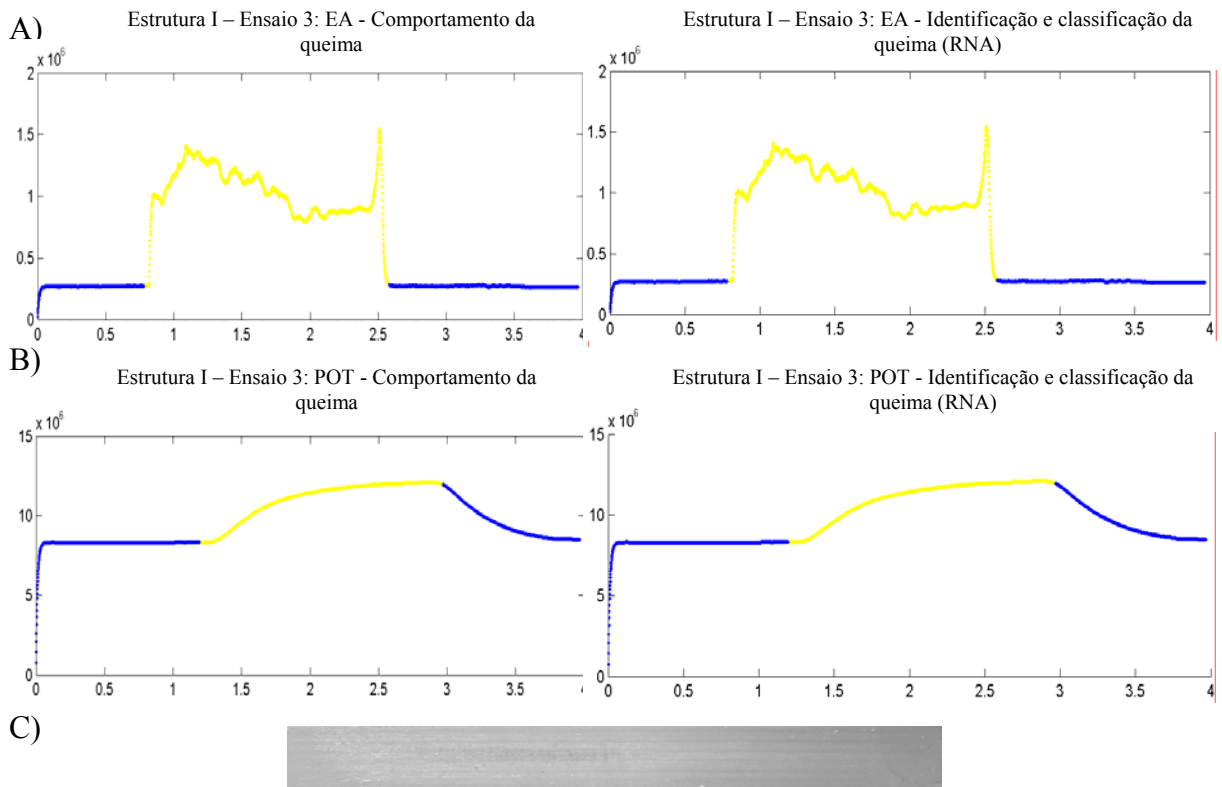


Figura 5.51 – Resultado da RNA (H3) para profundidade de 22,5 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.52 – Resultado da RNA (K1) para profundidade de 30,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.53 – Resultado da RNA (K2) para profundidade de 30,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.54 – Resultado da RNA (K3) para profundidade de 30,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.55 – Resultado da RNA (L1) para profundidade de 35,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K

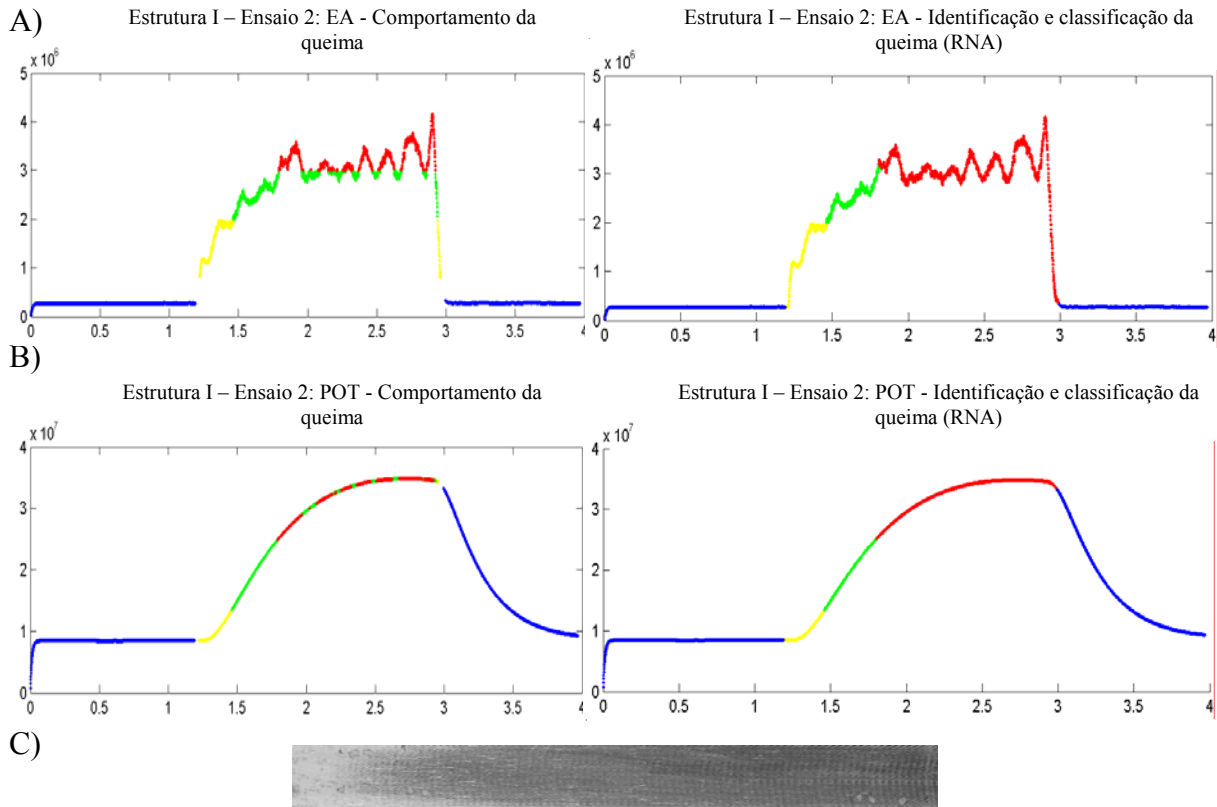


Figura 5.56 – Resultado da RNA (L2) para profundidade de 35,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K

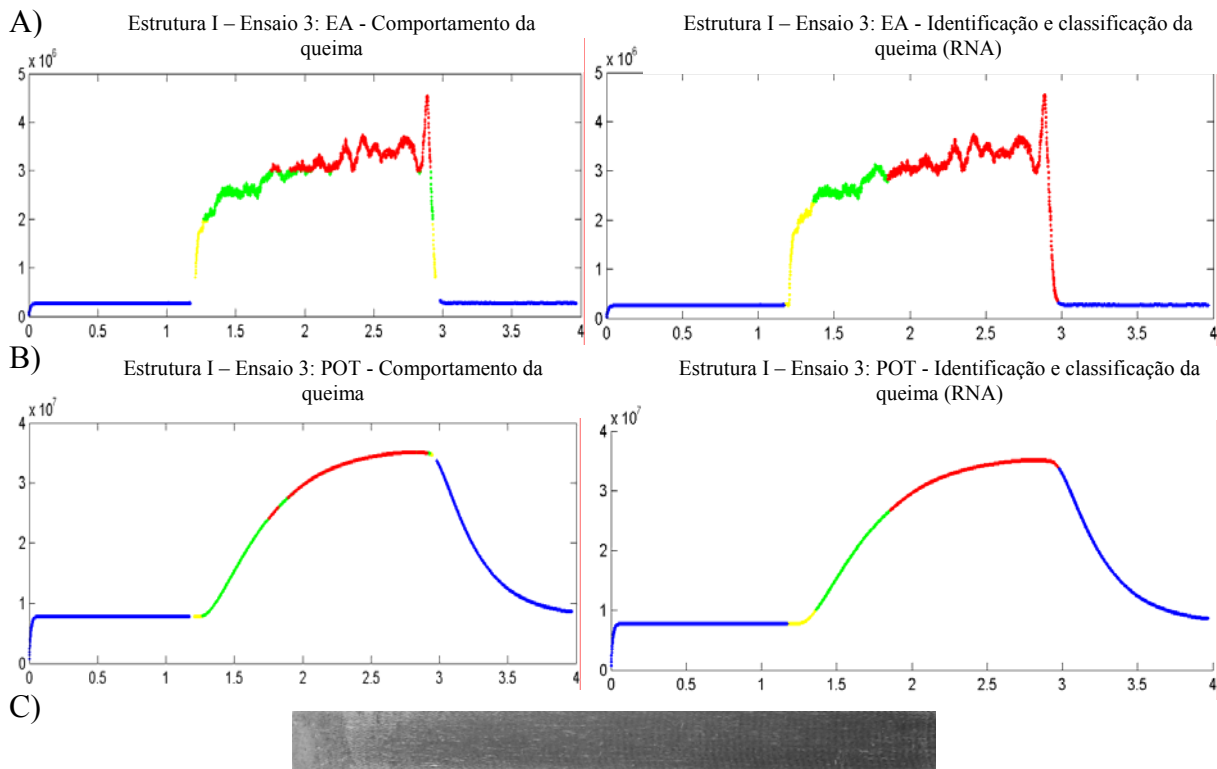


Figura 5.57 – Resultado da RNA (L3) para profundidade de 35,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.58 – Resultado da RNA (M1) para profundidade de 40,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.59 – Resultado da RNA (M2) para profundidade de 40,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.60 – Resultado da RNA (M3) para profundidade de 40,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.61 – Resultado da RNA (O1) para profundidade de 50,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.62 – Resultado da RNA (O2) para profundidade de 50,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.63 – Resultado da RNA (O3) para profundidade de 50,0 μ m.
 A) Sinal RMS; B) Sinal de Potência Elétrica; C) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K

5.4.6.2 RNA 2: DPO e Profundidade de corte (Estrutura II)

Nas Figuras 5.64 a 5.81, são mostrados os resultados obtidos pela estrutura II juntamente com as imagens das peças ensaiadas. Cor amarela (sem queima), cor verde (queima leve) e cor vermelha (queima severa).




Figura 5.64 – Resultado da RNA (C1) para profundidade de 10,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.65 – Resultado da RNA (C2) para profundidade de 10,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.66 – Resultado da RNA (C3) para profundidade de 10,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.67 – Resultado da RNA (H1) para profundidade de 22,5 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.68 – Resultado da RNA (H2) para profundidade de 22,5 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.69 – Resultado da RNA (H3) para profundidade de 22,5 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.70 – Resultado da RNA (K1) para profundidade de 30,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.71 – Resultado da RNA (K2) para profundidade de 30,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.72 – Resultado da RNA (K3) para profundidade de 30,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.73 – Resultado da RNA (L1) para profundidade de 35,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.74 – Resultado da RNA (L2) para profundidade de 35,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.75 – Resultado da RNA (L3) para profundidade de 35,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.76 – Resultado da RNA (M1) para profundidade de 40,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.77 – Resultado da RNA (M2) para profundidade de 40,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.78 – Resultado da RNA (M3) para profundidade de 40,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.79 – Resultado da RNA (O1) para profundidade de 50,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

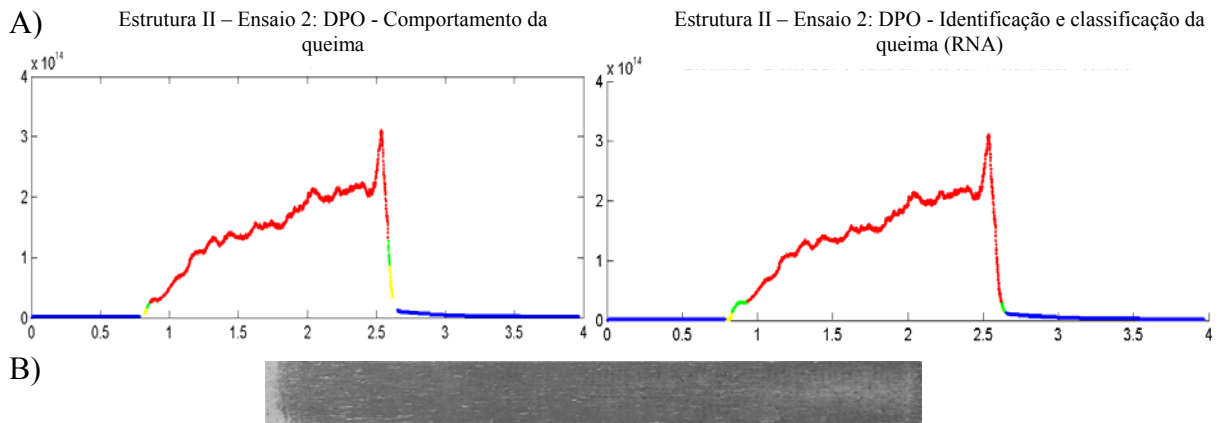


Figura 5.80 – Resultado da RNA (O2) para profundidade de 50,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.81 – Resultado da RNA (O3) para profundidade de 50,0 μ m.

A) Sinal DPO; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

5.4.6.3 RNA 3: DPKS e Profundidade de corte (Estrutura III)

Nas Figuras 5.82 a 5.99, são mostrados os resultados obtidos pela estrutura III juntamente com as imagens das peças ensaiadas. Cor amarela (sem queima), cor verde (queima leve) e cor vermelha (queima severa).




Figura 5.82 – Resultado da RNA (C1) para profundidade de 10,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.83 – Resultado da RNA (C2) para profundidade de 10,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.84 – Resultado da RNA (C3) para profundidade de 10,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.85 – Resultado da RNA (H1) para profundidade de 22,5 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.86 – Resultado da RNA (H2) para profundidade de 22,5 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.87 – Resultado da RNA (H3) para profundidade de 22,5 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.88 – Resultado da RNA (K1) para profundidade de 30,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.89 – Resultado da RNA (K2) para profundidade de 30,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.90 – Resultado da RNA (K3) para profundidade de 30,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.91 – Resultado da RNA (L1) para profundidade de 35,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.92 – Resultado da RNA (L2) para profundidade de 35,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.93 – Resultado da RNA (L3) para profundidade de 35,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.94 – Resultado da RNA (M1) para profundidade de 40,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.95 – Resultado da RNA (M2) para profundidade de 40,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.96 – Resultado da RNA (M3) para profundidade de 40,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.97 – Resultado da RNA (O1) para profundidade de 50,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.98 – Resultado da RNA (O2) para profundidade de 50,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.99 – Resultado da RNA (O3) para profundidade de 50,0 μ m.

A) Sinal DPKS; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

5.4.6.4 RNA 4: DAREA e Profundidade de corte (Estrutura IV)

Nas Figuras 5.100 a 5.117, são mostrados os resultados obtidos pela estrutura IV, juntamente com as imagens das peças ensaiadas. Cor amarela (sem queima), cor verde (queima leve) e cor vermelha (queima severa).




Figura 5.100 – Resultado da RNA (C1) para profundidade de 10,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.101 – Resultado da RNA (C2) para profundidade de 10,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.102 – Resultado da RNA (C3) para profundidade de 10,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.103 – Resultado da RNA (H1) para profundidade de 22,5 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.104 – Resultado da RNA (H2) para profundidade de 22,5 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.105 – Resultado da RNA (H3) para profundidade de 22,5 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.106 – Resultado da RNA (K1) para profundidade de 30,0 μ m.
 A) Sinal DAREA; B) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.107 – Resultado da RNA (K2) para profundidade de 30,0 μ m.
 A) Sinal DAREA; B) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.108 – Resultado da RNA (K3) para profundidade de 30,0 μ m.
 A) Sinal DAREA; B) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.109 – Resultado da RNA (L1) para profundidade de 35,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

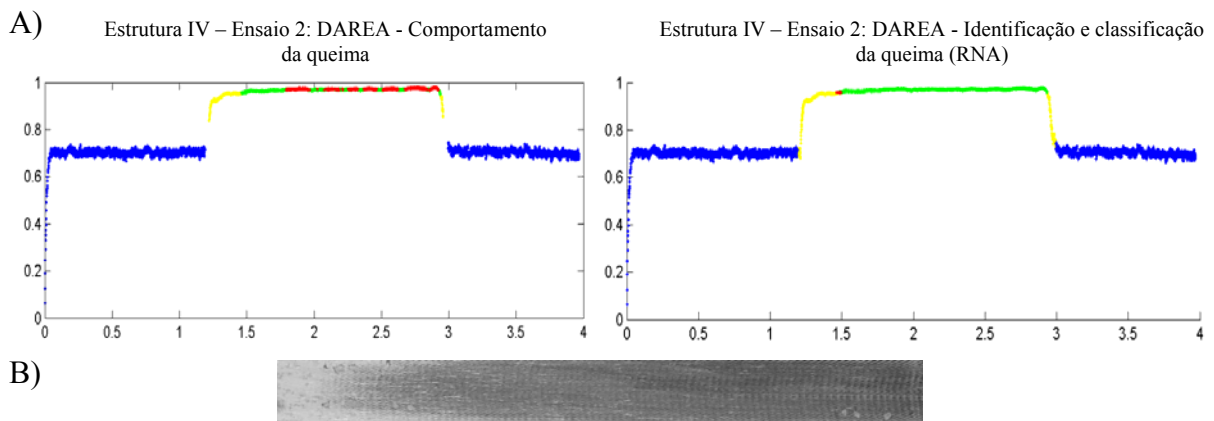


Figura 5.110 – Resultado da RNA (L2) para profundidade de 35,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

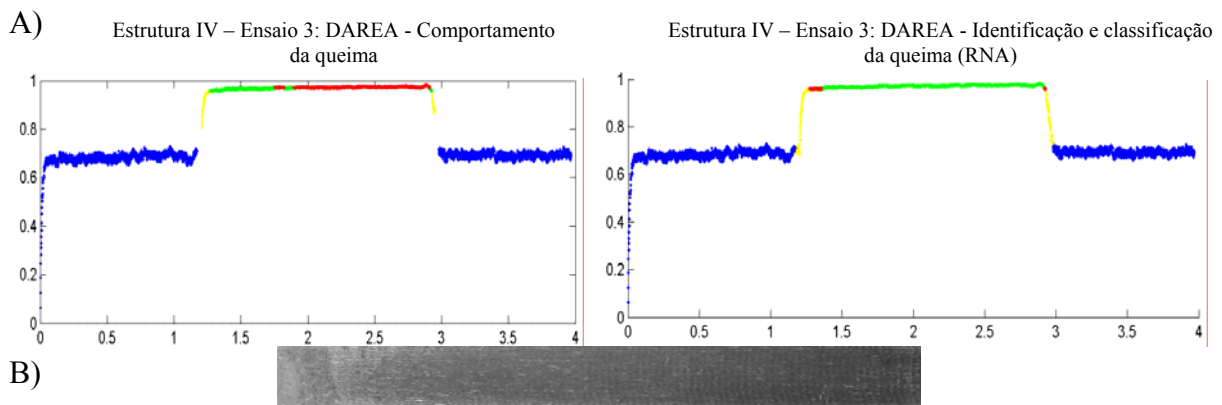


Figura 5.111 – Resultado da RNA (L3) para profundidade de 35,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

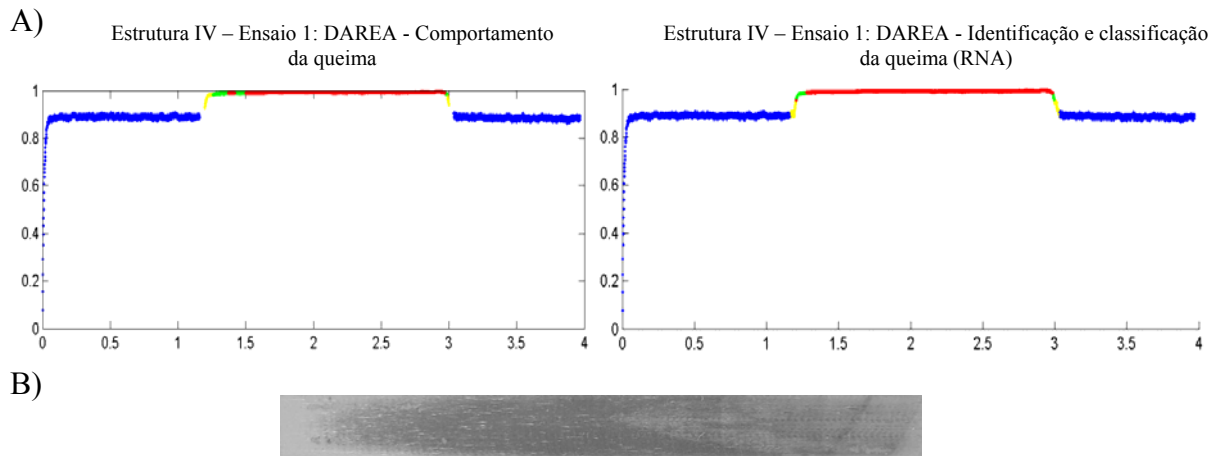


Figura 5.112 – Resultado da RNA (M1) para profundidade de 40,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.113 – Resultado da RNA (M2) para profundidade de 40,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K

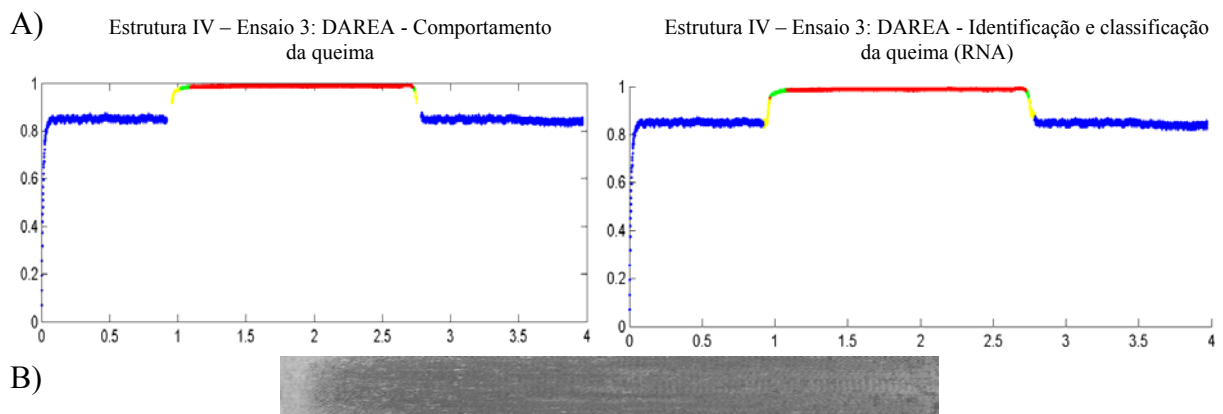


Figura 5.114 – Resultado da RNA (M3) para profundidade de 40,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.115 – Resultado da RNA (O1) para profundidade de 50,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.116 – Resultado da RNA (O2) para profundidade de 50,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.117 – Resultado da RNA (O3) para profundidade de 50,0 μ m.

A) Sinal DAREA; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K

5.4.6.5 RNA 5: DIFP e Profundidade de corte (Estrutura V)

Nas Figuras 5.118 a 5.135, são mostrados os resultados obtidos pela estrutura V juntamente com as imagens das peças ensaiadas. Cor amarela (sem queima), cor verde (queima leve) e cor vermelha (queima severa).




Figura 5.118 – Resultado da RNA (C1) para profundidade de 10,0μm.

A) Sinal DIFP; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts×K




Figura 5.119 – Resultado da RNA (C2) para profundidade de 10,0μm.

A) Sinal DIFP; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts×K




Figura 5.120 – Resultado da RNA (C3) para profundidade de 10,0μm.

A) Sinal DIFP; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts×K




Figura 5.121 – Resultado da RNA (H1) para profundidade de 22,5 μ m.

A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.122 – Resultado da RNA (H2) para profundidade de 22,5 μ m.

A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.123 – Resultado da RNA (H3) para profundidade de 22,5 μ m.

A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.124 – Resultado da RNA (K1) para profundidade de 30,0 μ m.
 A) Sinal DIFP; B) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K

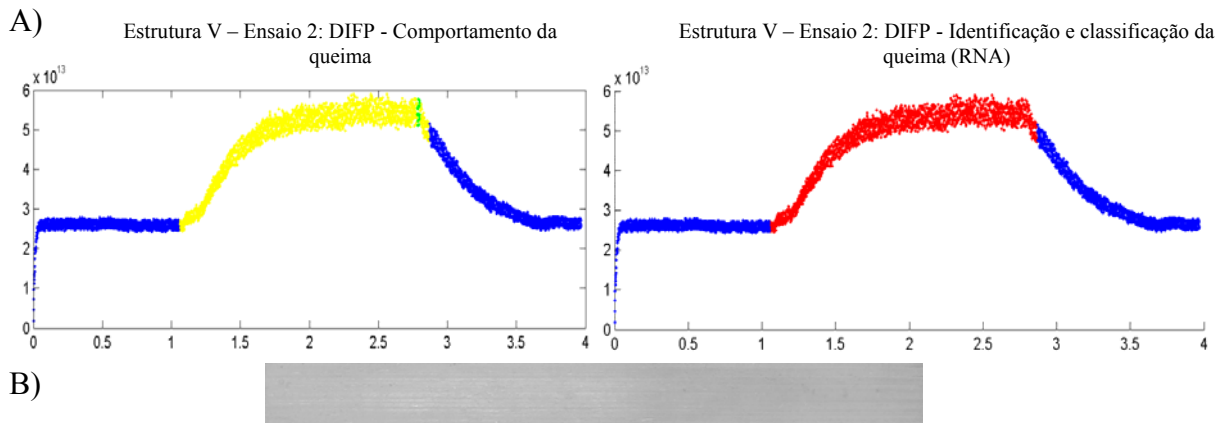


Figura 5.125 – Resultado da RNA (K2) para profundidade de 30,0 μ m.
 A) Sinal DIFP; B) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.126 – Resultado da RNA (K3) para profundidade de 30,0 μ m.
 A) Sinal DIFP; B) Imagem da peça usinada
 Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.127 – Resultado da RNA (L1) para profundidade de 35,0 μ m.

A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.128 – Resultado da RNA (L2) para profundidade de 35,0 μ m.

A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.129 – Resultado da RNA (L3) para profundidade de 35,0 μ m.

A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K

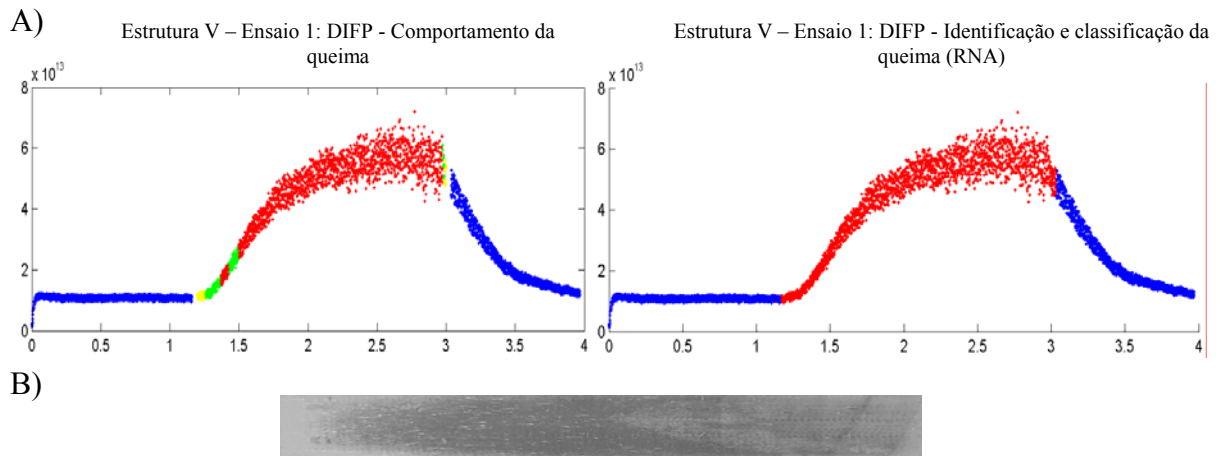


Figura 5.130 – Resultado da RNA (M1) para profundidade de 40,0 μ m.
Escala A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.131 – Resultado da RNA (M2) para profundidade de 40,0 μ m.
A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.132 – Resultado da RNA (M3) para profundidade de 40,0 μ m.
A) Sinal DIFP; B) Imagem da peça usinada
Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.133 – Resultado da RNA (O1) para profundidade de 50,0 μ m.

A) Sinal DIFP; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.134 – Resultado da RNA (O2) para profundidade de 50,0 μ m.

A) Sinal DIFP; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K




Figura 5.135 – Resultado da RNA (O3) para profundidade de 50,0 μ m.

A) Sinal DIFP; B) Imagem da peça usinada

Escala horizontal em segundos; Escala vertical em Volts \times K

5.4.6.6 Análise de Desempenho das V Estruturas de Redes Neurais Artificiais

Para uma melhor compreensão dos resultados obtidos e uma comparação entre as estruturas foi criada uma tabela onde é analisado o desempenho de cada uma das cinco estruturas de redes neurais artificiais (Tabela 5.5).

Tabela 5.5 – Desempenho das 5 Redes Neurais testadas.

ESTRUTURA	ANÁLISE DE DESEMPENHO	FIGURAS	RNA
			Saída esperada x Validada
I	Com base nas fotos das superfícies das peças apresentadas, nota-se que a classificação da queima, feita pela RNA foi satisfatória.	46 a 63	OK
II	Conforme observado nas fotos das peças ensaiadas, produziu bons resultados para os ensaios onde ocorreram queima severa, e não queima. Porém para as peças que apresentavam queima leve, a rede, que tinha como entradas o parâmetro DPO e profundidade de corte, não classificou de forma correta algumas mudanças de queima leve (cor verde) para queima severa (cor vermelha). Contudo, de acordo com os resultados em geral, pode-se considerar que a rede é eficaz na classificação da queima.	64 a 81	OK
III	O parâmetro DPKS juntamente com a profundidade de corte utilizados como entradas desta estrutura onde se mostrou eficiente na classificação da queima, acertando as mudanças de níveis.	82 a 99	OK
IV	Da mesma maneira que o parâmetro DPO, a estatística DAREA conseguiu classificar os níveis sem queima (cor amarela) e queima severa (cor vermelha). Porém para o nível intermediário de queima leve (cor verde) não foi detectado corretamente pela rede. Contudo esta estrutura de entrada pode ser usada em casos de detecção de queima e não queima.	100 a 117	OK
V	O parâmetro DIFP não classificou de forma correta os níveis de queima, pois detectou em todos os ensaios queima severa (cor vermelha). O desempenho desse parâmetro é explicado pelo fato de ser obtido pela média do sinal de emissão acústica, que não acusa mudanças ocorridas no processo de retificação.	118 a 135	NS*

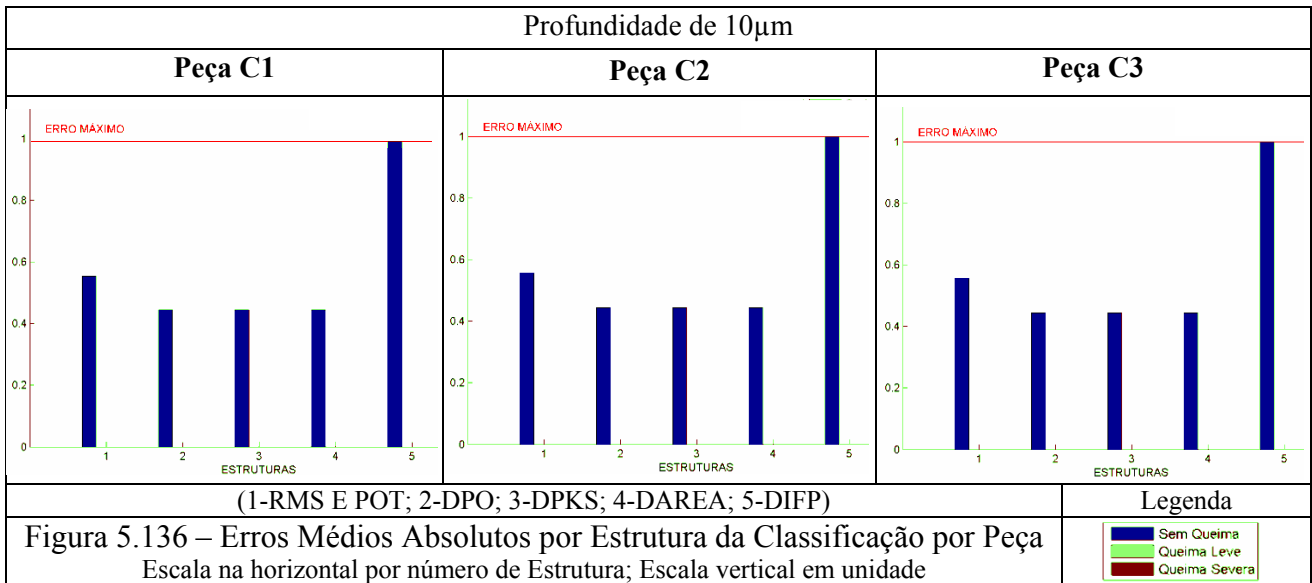
* NS: Não Satisfatória

5.4.6.7 Erros Médios Absolutos por Estrutura da Classificação


De forma a avaliar o desempenho das redes neurais na identificação do processo de queima, o erro médio absoluto para cada peça e respectivas estruturas neurais forma calculados conforme mostrado nas Figuras 5.136 a 5.141. Os erros médios absolutos foram calculados usando a expressão a seguir:

$$E_{\text{médio}} = \frac{\sum_1^{K=N} (\text{teórico}(k) - \text{estimada}(k))}{N} \quad (\text{Eq. 17})$$


Nesta expressão os valores de identificação de queima reais são subtraídos pelos valores obtidos das saídas das redes neurais, as diferenças são somadas e ponderados pelos números de amostras N. Deve ser observado que valores tendendo a 1 (um) correspondem à valores insatisfatórios.




A Figura 5.137, a rede, para a peça H1, H2 e H3, a estrutura V (DIFP) não conseguiu prever a resposta de “Sem Queima”, onde o resultado apresenta “Queima Severa”.




A Figura 5.138, a rede, para a peça K1 e K3, a estrutura V (DIFP) não conseguiu prever a resposta de “Sem Queima”, onde o resultado apresenta “Queima Severa”. Para a peça K2, a estrutura I, II, III e IV para a resposta “Sem Queima” conseguiu prever, já a estrutura V não conseguiu. Para a região com “Queima Leve”, a estrutura I, II e IV conseguiram prever a “Queima Leve”, conforme as Figuras 5.53, 5.71 e 5.107, a Estrutura III, Figura 5.89 e Estrutura V, Figura 5.126 não conseguiram.




A Figura 5.139, a rede, para a peça L1, a estrutura V (DIFP) não conseguiu prever a resposta de “Sem Queima” e “Queima Leve”, onde o resultado apresenta “Queima Severa”. Para as peças L2 e L3, a estrutura I, II, III e IV conseguiram prever, já a estrutura V conseguiu prever somente a “Queima Severa”, conforme as Figuras 5.56, 5.57, 5.74, 5.75, 5.92, 5.93, 5.109, 5.110, 5.128 e 5.129.



A Figura 5.140, a rede, para a peça M1, M2 e a peça M3 a estrutura III (DPKS) não conseguiu prever a resposta de “Sem Queima”, Estrutura V (DIFP) não conseguiu prever “Sem Queima” e “Queima Leve”. As demais conseguiram prever conforme as Figuras 5.58, 5.59, 5.60, 5.76, 5.77, 5.78, 5.94, 5.95, 5.96, 5.112, 5.113, 5.114, 5.130, 5.131 e 5.132.



A Figura 5.141, a rede, para as peças O1, O2 e O3 a estrutura III (DPKS) não conseguiu prever a resposta de “Sem Queima”, Estrutura V (DIFP) não conseguiu prever “Sem Queima” e “Queima Leve”. As demais conseguiram prever conforme as Figuras 5.61, 5.62, 5.63, 5.79, 5.80, 5.82, 5.97, 5.98, 5.100, 5.115, 5.116, 5.117, 5.133, 5.134 e 5.135.



O resumo dos erros médios absolutos da classificação conforme Tabela 5.6, onde o parâmetro DIFP, não conseguiu fazer a classificação para “Sem Queima” e “Queima Leve”, mas acertando 100% das “Queima Severa”. O DPKS acertou 100% da classificação de “Queima Leve” e “Queima Severa”

Tabela 5.6 – Classificação da queima (RNA)

		ERROS MÉDIOS ABSOLUTOS DA CLASSIFICAÇÃO																	
		ESTR. I						ESTR. II			ESTR. III			ESTR. IV			ESTR. V		
Prof. <i>a</i> [μ m]	Peça	EA _{RMS}			POT			DPO			DPKS			DAREA			DIFP		
		SQ	QL	QS	SQ	QL	QS	SQ	QL	QS	SQ	QL	QS	SQ	QL	QS	SQ	QL	QS
10,0	C1	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
	C2	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
	C3	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
22,5	H1	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
	H2	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
	H3	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
30,0	K1	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
	K2	✓	✓	-	✓	✓	-	✓	✓	-	✓	×	-	✓	✓	-	×	×	-
	K3	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
35,0	L1	✓	-	-	✓	-	-	✓	-	-	✓	-	-	✓	-	-	×	-	-
	L2	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	×	✓
	L3	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	×	✓
40,0	M1	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	×	×	✓
	M2	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	×	×	✓
	M3	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	×	×	✓
50,0	O1	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	×	×	✓
	O2	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	×	×	✓
	O3	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	×	×	✓

onde: ✓ - acerto; × - erro

Legenda: SQ= Sem Queima; QL= Queima Leve; QS= Queima Severa

6 CONCLUSÕES

Os resultados encontrados das análises realizadas, as RNA's convergiram bem para a classificação dos parâmetros estatísticos estudados. Os parâmetros que conseguiram detectar com êxito o tipo da queima foram o RMS e a POT. As estruturas que utilizaram a estatística DPO e DAREA juntamente com a profundidade de corte mostraram-se eficientes na detecção da queima, porém para níveis intermediários não houve uma classificação aceitável.

A escolha dos parâmetros de entrada da RNA's a fim de obter o melhor desempenho da classificação foram bons. O desempenho da rede em sua totalidade foi de 100% de acerto em relação à queima e não queima, porém em relação a classificação da queima ela teve erros em alguns parâmetros. Pela análise dos testes de microdureza comprova-se que houve alteração na estrutura superficial das peças, onde se pode visualizar a queima, o que vem de encontro com os resultados gerados quando a RNA foi alimentada com os dados obtidos do processamento digital dos sinais de EA e potência elétrica, confirmando assim a credibilidade na avaliação por ela realizada. É importante ressaltar que, estas estruturas, com exceção da estrutura V, funcionaram satisfatoriamente. Entretanto, caso exista uma mudança nos parâmetros de configuração no processo de retificação, a rede não consegue classificar de forma eficiente os níveis de queima. Sendo assim, seria necessário o remodelamento da estrutura da rede neural artificial. A partir disto, explorar o monitoramento da queima, na operação de retificação tangencial plana através de Redes Neurais Artificiais, se torna cada vez interessante para o processo de fabricação dos produtos manufaturados, reduzindo assim os retrabalhos e refugos oriundos deste processo.

7 SUGESTÕES PARA TRABALHOS FUTUROS

Como base nos estudos realizados e nas conclusões alcançadas, sugere-se:

- ✓ Utilização de outros parâmetros derivados da emissão acústica como dados de entrada da rede neural e a verificação de sua contribuição à classificação;
- ✓ Montagem de um sistema como um painel de comando, com controles gráficos capazes de monitorar constantemente a usinagem pela Rede Neural Artificial;
- ✓ Estrutura diversificada dos ensaios com base em todos os projetos consolidados frente à vantagem de buscar cada vez o aperfeiçoamento dos testes;
- ✓ Fazer mais implementações estatísticas que possibilitem a formação de bancos de dados capazes de absorver resultados cada vez mais rápidos;
- ✓ Aperfeiçoar as redes neurais artificiais a classificação da queima com parâmetros capazes de conhecer o sistema de dados coletados nos ensaios preliminares como resultados satisfatórios ou não, identificando assim sua validação futura.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, P. R. **Controle Automático de Danos Térmicos na Usinagem por Abrasão através do Processamento de Sinais de Emissão Acústica e Potência Elétrica.** Tese de Livre-docência, UNESP, Bauru, 2003, 204p.

AGUIAR, P. R. **Monitoramento da Queima Superficial em Processo de Usinagem por Retificação usando a Potência Elétrica do Motor de Acionamento e Emissão Acústica.** Tese de Doutorado apresentada à Escola Politécnica da Universidade de São Paulo, USP, 1997.

AGUIAR, P. R., BAGAGLI, R. P., BIANCHI, E. C. **A integridade superficial da peça monitorada por emissão acústica e potência elétrica no processo de retificação.** 8as Jornadas Portuguesas de TRIBOLOGIA - Novos Desenvolvimentos da Tribologia: Análise Teórica e Aplicada em Processos Industriais. Universidade de Aveiro, Portugal, 08 e 09 de maio de 2002. p. 245-249.

AGUIAR, P. R., SERNI, P. J. A., BIANCHI, E. C., DOTTO, F.R.L. **In-process grinding monitoring by acoustic emission In: International Conference on Acoustics, Speech, and Signal Processing.** Montreal, 2004.

AGUIAR, P. R., BIANCHI, E. C., DOTTO, F. R. L., FLAUZINO, R. A., SAPTTI, D. H. **Neural Network Applied To Detect Burn In Grinding.** XVIII Congresso Brasileiro de Engenharia Mecânica, Minas Gerais , 2005.

AGUIAR, P. R., OLIVEIRA, J. F. G. **Production Grinding Burn Detection Using Acoustic Emission and Electric Power Signals.** Abrasives Magazine, Jan. 1999. p. 16-24.

AGUIAR, P. R., WILLETT, P., WEBSTER, J. **Acoustic Emission Applied to Detect Workpiece Burn During Grinding.** International Symposium on Acoustic Emission: Standards and Technology Update, S. Vahaviolos, Ed., Fort Lauderdale, FL, January 1999.

BADGER, J. A., TORRANCE, A. **Understanding the causes of grinding burn helps alleviate the problem.** CUTTING TOOL ENGINEERING Magazine, U.S., Dec. 2000, v. 52, n. 12.

BERKOVITS, A. & FANG, D. **Study of Fatigue Crack Characteristics by Acoustic Emission.** Engineering Fracture Mechanics, v. 51(3), p. 401-416, 1995.

BIANCHI, E. C. **Ação das Condições de Dressagem na Retificação de Precisão.** Dissertação de mestrado apresentada à Escola de Engenharia de São Carlos, USP, 1990.

BIANCHI, E. C., SANCHES, L. E. A., FERNANDES, O. C., MOGAMI, O., SILVA JR, C. E. e AGUIAR, P. R. **Análise do Comportamento de Rebolos Convencionais na Retificação de Aços Frágeis.** Congresso Norte Nordeste de Engenharia Mecânica, IV, Recife/PE, p. 335-340, 1996.

BIANCHI, E. C.; SANCHES, L. E. A.; FERNANDES, O. C., MOGAMI, O.; SILVA JR, C. E. e AGUIAR, P. R. **Análise do Comportamento de Rebolos Convencionais na Retificação de Aços Dúcteis.** Congresso Norte Nordeste de Engenharia Mecânica, IV, Recife/PE, p. 387-392, 1996.

BICUDO, L. e FERNANDO, F.G. **Tecnologia.** Revista Máquinas e Metais, n. 363, p. 112-123, abril, 1996.

BIFANO, T. G. e YI, Y. **Acoustic Emission as an Indicator of Material-Removal Regime in Glass Micro-Machining.** Precision Engineering, v. 4, n. 4, p. 219-227, Oct. 1992.

BLUM, T. e DORNFELD, D. A. **Grinding Process Feedback using Acoustic Emission.** in: 4th International Grinding Conference, Dearborn (Detroit), Michigan, Oct., 1990.

CARVALHO, A. P. L. F. **Redes neurais artificiais.** Disponível em: <<http://www.icmc.usp.br/~andre/research/neural/>>. Acesso em: 11 fev. 2006.

CHANG, Y. P. e DORNFELD, D. A. **Chatter and Surface Pattern Detection for Cylindrical Grinding Using a Fluid Coupled Acoustic Emission Sensor**. p. 159-167, 1993.

DENNIS, P. e KAISER, M. **Profile grinding with dressable diamond and CBN wheels**. Industrial Diamond Review, p. 214-218, 1999. ISSN 0019-8145.

DINIZ, A. E.; CUPINI, N. L. e VILELLA, R. C. **Monitoramento do processo de usinagem por emissão acústica**. XI CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA, São Paulo, dezembro, 1991.

DOLINSEK, S. D. e KOPAC, J. **Acoustic emission signals for tool wear identification**. Wear, p. 225-229, 295-303, 1999.

DOTTO, F., R. L., AGUIAR, P., R., BIANCHI, E. C. **In-process thermal damage detection in grinding with monitoring via Internet**. Seventh International Conference on Control, Automation, Robotics and Vision, ICARCV 2002, Singapore, p. 2-5, Dec., 2002.

DOTTO, F. R. L. **Sistema de Detecção Automática On-Line de Danos Térmicos no Processo de Retificação com Monitoramento Via Internet**. Dissertação (Mestrado em Engenharia Industrial) - Universidade Estadual Paulista Júlio de Mesquita Filho, Bolsa da Fundação de Amparo à Pesquisa do Estado de São Paulo. Orientador: Paulo Roberto de Aguiar, p. 220, 2004.

HASSUI, A. **Estudo da Vibração Durante o Corte e Centelhamento na Retificação Cilíndrica de Mergulho**. Campinas, 2002. Tese (Doutorado em Engenharia Mecânica), Universidade de Campinas, UNICAMP.

HASSUI, A., DINIZ, A. E., OLIVEIRA, J. F. G., FELIPE, J., GOMES, J. J. F. **Experimental Evaluation on Grinding Wheel Wear through Vibration and Acoustic Emission**. Wear, p. 7-14, 1998.

HAYKIN, S. **Redes neurais: princípios e prática**. 2.^{ed}, Porto Alegre, Bookman, 2001.

INASAKI, I. **Sensor Fusion for Monitoring and Controlling Grinding Processes.** The International Journal of Advanced Manufacturing Technology, 1999, p. 730-736.

INASAKI, I. & OKAMURA, K. **Monitoring of dressing and grinding processes with acoustic emission signals.** Annals of the CIRP, v. 34/1, p. 277-280, 1985.

JOHNSON, C. D. **Process Control Instrumentation Technology.** Prentice Hall, 5^{ed}. New Jersey, 1997, p. 638.

JUNIOR, J. F. **Contribuição para implementação de funções de retificação inteligente (R.I.) utilizando técnicas de monitoramento por emissão acústica.** Tese (Doutorado) - USP, São Carlos – SP, p. 138, 1996.

KHENAIRES, M. **Utilização de Microprocessadores para Correção e Controle no Processo de Retificação.** Maio, 2006.

KIM, J. **Comparison of conventional and high speed grinding of AISI 52100 steel.** PhD. Thesis at University of Connecticut, 1997.

KING, R. I. & HAHN, R. S. **Handbook of modern technology.** New York, Chapman and Hall, 1986.

KOENIG, W. e KLUMPEN, T. **Monitoring and Sensor Concepts for Higher Process Reliability.** 5th Int. Grinding Conf., Cincinnati, Ohio, October 26-28, 1993.

KÖNIG, W. **Fertigungsverfahren Band 2, Schleifen, Honen, Laeften.** VDI Verlag, Dusseldorf, 1980.

KÖNIG, W., KNOP, M. **Retificação: métodos para prever o comportamento do processo.** Tradução: Norberto de Paula Lima, Adaptação: Alexandre T. Simon, Revista Máquinas e Metais, Fevereiro, 1991, p. 48-62.

KOVACS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações.** Texto Básico Escola Politécnica da Universidade de São Paulo, 2a. Edição, São Paulo, 1996.

KWAK J. S. e SONG, J. B. **Trouble diagnosis of the grinding process by using acoustic emission signals**. International Journal of Machine Tools & Manufacture, n. 41, p. 899-913, 2001.

LI, X. A. **brief review: acoustic emission method for tool wear monitoring during turning**. International Journal of Machine Tools & Manufacture, n.42, p.157-165, 2002.

MALKIN, S. **Grinding technology: theory and applications of machining abrasives**. England: Ellis Horwood Limited, 1989, 275p.

NATHAN, R. DEIVA; VIJAYARAGHAVAN, L.e KRISHNAMURTHY, R. **In-process monitoring of grinding burn in the cylindrical grinding of steel**. Journal of Materials Processing Technology, v.91, Issue 1-3, June, 1999, p. 37-42.

NONDESTRUCTIVE TESTING HANDBOOK. **Acoustic Emission Testing**. Volume 5. Ronnie K. Miller (Technical Editor). Paul McIntire (Editor). American Society for Nondestructive Testing, 1987. ISBN 0-931403-02-2.

OLIVEIRA, A.C. **Aplicação – Redes neurais**. Disponível em: < http://equipe.nce.ufrj.br/thomé/grad/nn/mat_didatico/ic_grad2002_aula4.pdf>. Acesso em: 11 set. 2006.

OLIVEIRA, J. F. G. **Intelligent Grinding Systems (IGS): High Reliability and Automation Level in Precision Grinding**. Abrasives Magazine, p. 11-22, June/July, 1998b.

PANSANATO, L.; AGUIAR, P. R.; BIANCHI, E. C.; MORI, A. K. O. **Processamento do Sinal Bruto de Emissão Acústica e Velocidade de Corte na Detecção de Dano Térmico na Retificação Plana**. In: CONGRESSO SAE BRASIL, São Paulo, 2002, n.276, p. 1-6.

PRICKEN, W. **Dressing of vitrified bond wheels with CVDRESS and MONODRESS**. Industrial Diamond Review, v. 59, n.582, 1999, p. 225-231. ISSN 0019-8145.

RABELLO, R. S. **Redes neurais artificiais**. Disponível em: <<http://lci.upf.tche.Br/~roberto/rnr/IA%20-%202028-10-02/Redes%20Neurais%20-%20passo%20a%20passo.htm>>. Acesso em: 1 mar. 2006.

RAJAGOPALAN, R. & RAJAGOPALAN, P. **Applications of neural networks in manufacturing**. Proceedings of the 29th Annual Hawaii International Conference on System Sciences, p. 447-453, 1996.

ROWE, W. B.; LI, Y.; MILLS, B. e ALLANSON, D. R. **Applicationa of intelligent CNC in grinding, Computers in Industry**. v. 31, p. 45-60, 1996.

SALMON, S. C. **Unpublished work**. University of Bristol, 1988.

SHAFTO, G. R. **Creep Feed Grinding**. Ph.D. Thesis, University of Bristol, 1975.

SOUZA, M. C. Florenzano. **Manufatura virtual: conceituação e desafios**. Dezembro de 2002, p. 297-312, GESTÃO & PRODUÇÃO, v. 9, n. 3.

STEMMER, C. E. **Ferramentas de corte II: brocas, alargadores, ferramentas de roscar, fresas, brochas, rebolos, abrasivos**. Editora da UFSC, Florianópolis, 314 p., 1992.

TAFNER, M. A. **Estagiamento automático do sono utilizando um canal de EEG e uma rede neural artificial com alta representação cortical**. Tese (Doutor em Engenharia de Produção) – Departamento de Engenharia de Produção e Sistemas – Universidade Federal de Santa Catarina, Florianópolis, 1999. Disponível em: <<http://www.eps.ufsc.br/teses99/tafner/>>. Acesso em: 11 fev. 2006a.

TAFNER, M. A. **O que são as redes neurais artificiais**. Disponível em: <<http://www.cerebromente.org.br/n05/tecnologia/rna.htm>>. Acesso em: 11 fev. 2006b.

TANURI, M. G. **Inteligência Artificial: Novas Perspectivas**. Disponível em: <<http://www.facom.ufba.br/acm/gabriela.html>>. Acesso em: 01 mar. 2006.

TEIXEIRA, M. S. **Redes Neurais Artificiais Aplicadas no Monitoramento da Condição de Ferramentas de Corte Utilizando Algoritmo de Extração das Características SFS**. Proceedings of the IV Brazilian Conference on Neural Networks - IV Congresso Brasileiro de Redes Neurais, p. 292-297, ITA, São José dos Campos - SP – Brazil, July 20-22, 1999.

THOMÉ, A. C. G. e OLIVEIRA, A. C. **Redes neurais**. Disponível em: <http://equipe.nce.ufrj.br/thome/grad/nn/mat_didatico/ic_grad2002_aula3.pdf>. Acesso em: 1 mar. 2006.

VIEIRA, J. M. e OLIVEIRA, J. F. G. **Monitoring of plunge center-less grinding through acoustic emission**. Abrasives Magazine, December/January, 2002.

VIJAYARAGHAVAN, L.; KRISHNAMURTHY, R. e SARAVANAPRIYAN, A. **On-line detection of grinding burn by integrated sensing**. SIcon'01 SAensors for industry conference, Rosemount, Illinois, USA, 5-7 november, 2001.

WANG, Z.; WILLET, P.; AGUIAR, P. R.; WEBSTER, J. **Neural Network Detection Grinding Burn from Acoustic Emission**. International Journal of Machine Tools & Manufacture, v. 41, p. 283-309, 2001.

WASCHKIES, E., SKLARCZYK, C., AND HEPP, K. **Tool Wear Monitoring at Turning**. ASME Journal of Engineering and Industry, v. 116, 1994, p. 521-524.

WEBSTER, J.; MARINESCU, I.; BENNET, R. **Acoustic emission for process control and monitoring of surface integrity during grinding**. Annals of the CIRP, v. 43/1, 1994, p. 299-304.

YASUI, H. & TSUKUDA, S. **Influence of Fluid Type of Wet Grinding Temperature**. Bull. Japan Soc. of Prec. Eng., v. 17, n. 2, p. 133-134, 1983.

ANEXO A - RNA DESENVOLVIDA E APLICADA

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% RNA Determinação da Classificação da queima
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

load arquivo_entradas_3;
entrms=cat(2,sem_queima_rms,queima_leve_rms,queima_severa_rms);
entpot=cat(2,sem_queima_pot,queima_leve_pot,queima_severa_pot);
entdpo=cat(2,sem_queima_dpo,queima_leve_dpo,queima_severa_dpo);
entdpks=cat(2,sem_queima_dpks,queima_leve_dpks,queima_severa_dpks);
entdarea=cat(2,sem_queima_darea,queima_leve_darea,queima_severa_darea);
entdifp=cat(2,sem_queima_difp,queima_leve_difp,queima_severa_difp);
entprof=cat(2,sem_queima_prof,queima_leve_prof,queima_severa_prof);
entprof=entprof/10;
entrada1= cat(1,entrms,entpot,entprof);
entrada2= cat(1,entdpo,entprof);
entrada3= cat(1,entdpks,entprof);
entrada4= cat(1,entdarea,entprof);
entrada5= cat(1,entdifp,entprof);
queima_xx1=entrada1;
queima_xx2=entrada2;
queima_xx3=entrada3;
queima_xx4=entrada4;
queima_xx5=entrada5;

[queima_xxn1,min_x1,max_x1]=premnmx(queima_xx1);
[queima_xxn2,min_x2,max_x2]=premnmx(queima_xx2);
[queima_xxn3,min_x3,max_x3]=premnmx(queima_xx3);
[queima_xxn4,min_x4,max_x4]=premnmx(queima_xx4);
[queima_xxn5,min_x5,max_x5]=premnmx(queima_xx5);

%%%saida
%sem queima = 0 0 0
%queima leve = 0 1 0
%queima severa = 1 0 0

queima_yy1(1:389,1)= 0; queima_yy1(1:389,2)= 0; queima_yy1(1:389,3)= 1;
queima_yy1(390:833,1)= 0; queima_yy1(390:833,2)= 1; queima_yy1(390:833,3)=
0;
queima_yy1(834:1472,1)= 1; queima_yy1(834:1472,2)=
0;queima_yy1(834:1472,3)= 0;

%2 3 4 5 estrutura saida
queima_yy2=queima_yy1;
queima_yy3=queima_yy1;
queima_yy4=queima_yy1;
queima_yy5=queima_yy1;

%Criando "t" p/ o treinamento e "v" para a validação sendo que t=75% e
v=25% do total

%Entrada:

queima_x1=queima_xxn1;
queima_x2=queima_xxn2;
queima_x3=queima_xxn3;
queima_x4=queima_xxn4;
queima_x5=queima_xxn5;
tx1=queima_x1(:,1:3);
tx2=queima_x2(:,1:3);
```

```

tx3=queima_x3(:,1:3);
tx4=queima_x4(:,1:3);
tx5=queima_x5(:,1:3);
vx1=queima_x1(:,4);
vx2=queima_x2(:,4);
vx3=queima_x3(:,4);
vx4=queima_x4(:,4);
vx5=queima_x5(:,4);

k=1;

for i=1:4:(1472-30)
    tx1=cat(2,tx1,queima_x1(:,i+4:i+6));
    tx2=cat(2,tx2,queima_x2(:,i+4:i+6));
    tx3=cat(2,tx3,queima_x3(:,i+4:i+6));
    tx4=cat(2,tx4,queima_x4(:,i+4:i+6));
    tx5=cat(2,tx5,queima_x5(:,i+4:i+6));
    vx2=cat(2,vx2,queima_x2(:,i+7));
    vx3=cat(2,vx3,queima_x3(:,i+7));
    vx4=cat(2,vx4,queima_x4(:,i+7));
    vx5=cat(2,vx5,queima_x5(:,i+7));

end

%Saida:
queima_y1=queima_yy1';
queima_y2=queima_yy2';
queima_y3=queima_yy3';
queima_y4=queima_yy4';
queima_y5=queima_yy5';
ty1=queima_y1(:,1:3);
ty2=queima_y2(:,1:3);
ty3=queima_y3(:,1:3);
ty4=queima_y4(:,1:3);
ty5=queima_y5(:,1:3);
vy2=queima_y2(:,4);
vy3=queima_y3(:,4);
vy4=queima_y4(:,4);
vy5=queima_y5(:,4);

for i=1:4:(1472-30)
    ty1=cat(2,ty2,queima_y1(:,i+4:i+6));
    ty2=cat(2,ty2,queima_y2(:,i+4:i+6));
    ty3=cat(2,ty3,queima_y3(:,i+4:i+6));
    ty4=cat(2,ty4,queima_y4(:,i+4:i+6));
    ty5=cat(2,ty5,queima_y5(:,i+4:i+6));
    vy1=cat(2,vy2,queima_y1(:,i+7));
    vy2=cat(2,vy2,queima_y2(:,i+7));
    vy3=cat(2,vy3,queima_y3(:,i+7));
    vy4=cat(2,vy4,queima_y4(:,i+7));
    vy5=cat(2,vy5,queima_y5(:,i+7));
end

%=====
%Criacao da Rede estrutura 1
%=====

PR1 = [min(queima_xx1(1,:)) max(queima_xx1(1,:)); min(queima_xx1(2,:))
max(queima_xx1(2,:))];

```

```

net1 = newff (minmax(tx1), [11 3], {'logsig' 'logsig'}, 'traingdx');
net1.trainParam.epochs = 20000;
net1.trainParam.goal = 1e-6;
net1.trainParam.lr = 0.6;
net1.trainParam.mc = 0.5;
net1.trainParam.show=1000;
net1.trainParam.lr_inc = 1.05;
net1.trainParam.lr_dec = 0.7;
net1.trainParam.max_perf_inc = 1.04;

[net1,tra1] = train(net1,tx1,ty1);
tra1=tra1.perf(end);

%=====
%criando rede estrutura 2
%=====

net2 = newff (minmax(tx2), [11 3], { 'logsig' 'logsig' }, 'traingdx');
net2.trainParam.epochs = 20000;
net2.trainParam.goal = 1e-6;
net2.trainParam.lr = 0.6;
net2.trainParam.mc = 0.5;
net2.trainParam.show=1000;
net2.trainParam.lr_inc = 1.05;
net2.trainParam.lr_dec = 0.7;
net2.trainParam.max_perf_inc = 1.04;

[net2,tra2] = train(net2,tx2,ty2);
tra2=tra2.perf(end);

%=====
%criando rede estrutura 3
%=====

net3 = newff (minmax(tx3), [11 3], { 'logsig' 'logsig' }, 'traingdx');
net3.trainParam.epochs = 20000;
net3.trainParam.goal = 1e-6;
net3.trainParam.lr = 0.6;
net3.trainParam.mc = 0.5;
net3.trainParam.show=1000;
net3.trainParam.lr_inc = 1.05;
net3.trainParam.lr_dec = 0.7;
net3.trainParam.max_perf_inc = 1.04;

[net3,tra3] = train(net3,tx3,ty3);
tra3=tra3.perf(end);

%=====
%criando rede estrutura 4
%=====

net4 = newff (minmax(tx4), [11 3], {'logsig' 'logsig' }, 'traingdx');
net4.trainParam.epochs = 20000;
net4.trainParam.goal = 1e-6;
net4.trainParam.lr = 0.6;
net4.trainParam.mc = 0.5;
net4.trainParam.show=1000;
net4.trainParam.lr_inc = 1.05;
net4.trainParam.lr_dec = 0.7;
net4.trainParam.max_perf_inc = 1.04;

[net4,tra4] = train(net4,tx4,ty4);
tra4=tra4.perf(end);

```

```

%=====
%criando rede estrutura 5
%=====
net5 = newff (minmax(tx5), [11 3], {'logsig' 'logsig'}, 'traingdx');
net5.trainParam.epochs = 20000;
net5.trainParam.goal = 1e-6;
net5.trainParam.lr = 0.6;
net5.trainParam.mc = 0.5;
net5.trainParam.show=1000;
net5.trainParam.lr_inc = 1.05;
net5.trainParam.lr_dec = 0.7;
net.trainParam.max_perf_inc = 1.04;

[net5,tra5] = train(net5,tx5,ty5);
tra5=tra5.perf(end);

save('redes_neurais3','net1','net2','net3','net4','net5','min_x1','max_x1',
'min_x2','max_x2','min_x3','max_x3','min_x4','max_x4','min_x5','max_x5','tr
a1','tra2','tra3','tra4','tra5'

```

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)