



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru



ESTUDO DA PREDIÇÃO DA CIRCULARIDADE E RUGOSIDADE DE PEÇAS RETIFICADAS UTILIZANDO AS REDES NEURAIS ARTIFICIAIS

THIAGO VALLE FRANÇA

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

**BAURU – SP
Fevereiro – 2005**



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru



ESTUDO DA PREDIÇÃO DA CIRCULARIDADE E RUGOSIDADE DE PEÇAS RETIFICADAS UTILIZANDO AS REDES NEURAIS ARTIFICIAIS

THIAGO VALLE FRANÇA

Orientador: Prof. Dr. Paulo Roberto de Aguiar

Co-orientador: Prof. Dr. Eduardo Carlos Bianchi

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

**BAURU – SP
Fevereiro – 2005**

DEDICATÓRIA

Aos meus pais Carlos Alberto França de Oliveira e Conceição de Maria Valle França e as minhas irmãs Carla Valle França e Carolina Valle França.

AGRADECIMENTOS

Agradeço primeiramente e especialmente à Deus por ter me concedido saúde, disposição e capacidade para a realização desta pesquisa científica.

Agradeço ao meu orientador Prof. Dr. Paulo Roberto de Aguiar, do Departamento de Engenharia Elétrica, da Faculdade de Engenharia, da UNESP de Bauru, pelo constante auxílio, paciência, amizade e pela confiança em meu potencial acadêmico, apoiando e me incentivando nos momentos difíceis que apareceram durante a realização deste trabalho, buscando sempre extrair deste os melhores 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 aceitado me ajudar com a maior cordialidade e confiança.

Ao Prof. Dr. Leonardo Roberto da Silva do CEFET de Belo Horizonte – MG, que colaborou com opiniões e esclarecimentos técnicos sempre pertinentes.

À Faculdade de Odontologia da USP, na pessoa do Prof. Dr. César Antunes de Freitas, pela colaboração e sugestões sempre revolucionárias.

Agradeço à CAPES, pelo concessão da bolsa de mestrado, que foi de fundamental importância para o desenvolvimento desta pesquisa.

Agradeço à Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pelo auxílio financeiro para a aquisição dos materiais utilizados neste trabalho.

À Faculdade de Engenharia da Universidade Estadual Paulista - *campus* de Bauru, com distinção ao Departamento de Engenharia Mecânica e Engenharia Elétrica com seus respectivos laboratórios, LUA – Laboratório de Usinagem por Abrasão e LADAPS – Laboratório de Aquisição e Processamento de Sinais, que me acolheram com muita presteza.

Aos docentes do Departamento de Engenharia Mecânica da UNESP de Bauru, que contribuíram para a realização desta pesquisa, quer seja com sugestões, quer com conselhos, notoriamente, aos Professores Doutores Luiz Eduardo de Angelo Sanchez, Luiz Daré Neto, Célio Losnak, Marcos Tadeu Tibúrcio Gonçalves, Ivaldo De Domenico Valarelli, João Eduardo Guarnetti dos Santos e Vicente Luiz Scalon.

Aos Doutores Rodrigo Eduardo Catai e Eraldo Jannone da Silva, aos Mestres Rodrigo Daun Monici e Sidney Domingues e ao Engenheiro Thiago Magagnin os quais colaboraram com amizade e informações úteis à pesquisa.

Aos alunos de graduação em Engenharia Mecânica da UNESP de Bauru, Felipe Montebugnoli Zilio, José Augusto Camargo Alves, Renison Reis da Silva, Mariele da Silva, Lúcio Roberto da Silva Santana e Carlos Eduardo Dorigatti Cruz que foram de grande importância no desenvolvimento deste trabalho.

Agradeço aos técnicos Uilson Kruger (Alemão) do Laboratório de Usinagem por Abrasão, Osmar Luiz Martinelli do Laboratório de Engenharia Elétrica e Hamilton José de Mello do Laboratório de Materiais, todos da Faculdade de Engenharia da Universidade Estadual Paulista - *campus* de Bauru, por gentilmente colaborarem neste projeto.

Aos meus grandes companheiros de república Ronaldo Yoshinobu Füsse e Luciano Henrique de Almeida, assim como para as minhas queridas amigas Juliana Maria de Albuquerque Gimenez e Terlize Cristina Niemeyer, pelas conversas proveitosas, baladas, peladas e constante presença e apoio em todos os momentos.

Agradeço às Empresas SHELL e AGENA pela doação dos fluidos de corte utilizados nesta pesquisa.

E por fim, agradeço aos meus queridos companheiros de longa data, sempre concentrados na árdua tarefa de me mostrar o caminho mais correto e justo nos grandes percalços da vida.

**“Mestre não é quem sempre ensina,
mas quem de repente aprende”
(João Guimarães Rosa)**

SUMÁRIO

DEDICATÓRIA	1
AGRADECIMENTOS	ii
LISTA DE FIGURAS.....	viii
LISTA DE TABELAS	xiii
LISTA DE ABREVIATURAS E SÍMBOLOS.....	xiv
RESUMO.....	xvi
ABSTRACT	xvii
1 INTRODUÇÃO	1
1.1 ESTRUTURA DO TRABALHO.....	1
2 OBJETIVO	3
3 JUSTIFICATIVAS PARA A REALIZAÇÃO DESTA PESQUISA	4
4 REVISÃO BIBLIOGRÁFICA	5
4.1 A RETIFICAÇÃO CILÍNDRICA EXTERNA.....	5
4.1.1 Variáveis de Saída	7
4.1.1.1 Força tangencial de corte (F_t) e energia específica de retificação (u)	8
4.1.1.2 Emissão acústica (EA) e o parâmetro DPO	9
4.1.1.3 Circularidade	12
4.1.1.4 Rugosidade	14
4.1.1.5 Desgaste diametral do rebolo ($\Delta\emptyset$)	14
4.1.2 Formação do Cavaco	15
4.1.2.1 Forças de deslizamento.....	15
4.1.2.2 <i>Plowing</i> e formação do cavaco	16
4.1.2.3 Energia específica de retificação	17
4.2 A FERRAMENTA DE CORTE	19
4.2.1 Abrasivos.....	19
4.2.1.1 Superabrasivo de CBN	21
4.2.2 Ligante.....	22
4.2.3 Dureza	23
4.2.4 Granulometria.....	23
4.2.5 Estrutura	23
4.3 O PERFILAMENTO E A AFIAÇÃO DA FERRAMENTA	23
4.3.1 Ferramentas de Dressagem.....	24
4.4 A LUBRI-REFRIGERAÇÃO NO PROCESSO DE RETIFICAÇÃO	25
4.4.1 Fluidos de Corte	25

4.4.1.1 Fluidos de corte solúveis em água	26
4.4.2 Funções do Fluido de Corte	27
4.4.3 Otimização da Aplicação de Fluidos de Corte	27
4.4.3.1 A quebra da barreira aerodinâmica	30
4.5 A REDE NEURAL ARTIFICIAL - RNA	33
4.5.1 Introdução	33
4.5.2 O Neurônio Artificial	37
4.5.3 Arquitetura da RNA	39
4.5.4 Aplicações	41
4.5.5 Principais Características das Redes Neurais Artificiais	42
4.5.6 Treinamentos de Redes Neurais Artificiais	43
4.5.7 Tipos de RNA's	43
4.5.7.1 <i>Perceptron</i>	44
4.5.7.2 <i>Perceptron</i> multicamadas e backpropagation	46
4.5.8 Taxa de Aprendizado e <i>Momentum</i>	48
4.5.9 Validação Cruzada (<i>Cross-Validation</i>)	49
4.5.10 Redes Neurais Artificiais Aplicadas na Manufatura	49
5 MATERIAIS E MÉTODOS	53
5.1 EQUIPAMENTOS UTILIZADOS	53
5.1.1 Equipamentos do Sistema de Aquisição de Dados	54
5.1.1.1 Emissão acústica	54
5.1.1.2 Rotação da ferramenta	54
5.1.1.3 Potência elétrica do motor	55
5.1.1.4 Condicionadores de sinais e placa (A/D)	55
5.1.1.5 <i>Softwares</i>	56
5.2 MATERIAIS UTILIZADOS	57
5.2.1 Rebolo	57
5.2.2 Corpo de Prova	57
5.2.3 Fluido de Corte	58
5.3 VARIÁVEIS DE SAÍDA	59
5.3.1 Variáveis de Saída Direta	59
5.3.1.1 Medição da força tangencial de corte, energia específica de retificação e parâmetro DPO	59
5.3.1.2 Medição da emissão acústica (EA)	62
5.3.1.3 O programa <i>VI</i>	63
5.3.2 Variáveis de Saída Indireta	64
5.3.2.1 Medição da rugosidade e circularidade	64
5.3.2.2 Medição do desgaste diametral do rebolo	67
5.4 PLANEJAMENTO DOS ENSAIOS	67
5.4.1 Ensaios Preliminares	68
5.4.2 Escolha dos Parâmetros para os Ensaios Definitivos	71
5.5 PROCEDIMENTOS PRELIMINARES	72
5.5.1 Afiação da Ferramenta de Corte	72
5.5.2 Posicionamento do Defletor e Bocal	73
5.5.3 Ajuste do Fluido de Corte	74

5.6 ENSAIOS DE USINAGEM	74
5.6.1 Classificação dos Ensaios de Usinagem	74
5.6.2 Descrição dos Ensaios de Usinagem	76
5.6.3 Procedimentos Pós-ensaio.....	77
5.7 MODELAMENTO DAS REDES NEURAIS ARTIFICIAIS	78
5.7.1 Dados de Entrada.....	78
5.7.2 Configuração das Redes Neurais Artificiais	82
5.7.3 Escolha dos Parâmetros dos Testes	82
5.7.4 Determinação da Camada Oculta	83
5.8 COMPARAÇÃO FINAL ENTRE AS RNA'S	86
6 RESULTADOS E DISCUSSÕES	90
6.1 RESULTADOS DOS ENSAIOS DE USINAGEM	90
6.1.1 Força Tangencial de Corte (F_t).....	91
6.1.2 Energia Específica de Retificação (u).....	100
6.1.3 Emissão Acústica (EA)	109
6.1.4 Parâmetro DPO	117
6.1.5 Desgaste Diametral do Rebolo	126
6.1.6 Rugosidade	127
6.1.7 Circularidade	128
6.2 RESULTADOS DAS REDES NEURAIS ARTIFICIAIS	130
6.2.1 Escolha do Número de Neurônios da Camada Oculta.....	130
6.2.1.1 RNA's da base de dados A	130
6.2.1.2 RNA's da base de dados B	145
6.2.2 Comparação Entre as RNA's.....	158
7 CONCLUSÕES.....	163
8 SUGESTÕES PARA TRABALHOS FUTUROS	164
REFERÊNCIAS BIBLIOGRÁFICAS	165

LISTA DE FIGURAS

Figura 4.1 – Caracterização do processo de retificação cilíndrica externa de mergulho (MALKIN, 1989 - Adaptada).	6
Figura 4.2 – <i>Spark-out</i> no ciclo de retificação cilíndrica de mergulho (MALKIN, 1989 - Adaptada).	7
Figura 4.3 – Origem do sinal de emissão acústica no processo de retificação (BIFFI, 2003 - Adaptada).	10
Figura 4.4 – Exemplo de uma peça com erro de circularidade (TAYLOR-HOBSON, 2000).	12
Figura 4.5 – (a) Peça retificada com rebolo balanceado e (b) peça retificada com rebolo desbalanceado.	13
Figura 4.6 – Curva hipotética do comportamento tensão-deformação para um cisalhamento adiabático até a fusão do material (MALKIN, 1989 - Adaptada).	18
Figura 4.7 – Bocal de formato arredondado (WEBSTER, 1995).	28
Figura 4.8 – Bocal tradicional (WEBSTER, 1995).	28
Figura 4.9 – Velocidade crítica do rebolo com e sem dispositivo (<i>air scrapper</i>) de quebra de barreira aerodinâmica (CAMPBELL, 1995 - Adaptada).	31
Figura 4.10 – Efeito do dispositivo (<i>air scrapper</i>) na medida da pressão hidrodinâmica e fluxo de fluido de corte (CAMPBELL, 1995 - Adaptada).	32
Figura 4.11 – Neurônio biológico (acima) e neurônio artificial (abaixo). Onde: $\mathbf{x}$ é o vetor entrada; $\mathbf{w}$ o vetor peso, θ_k o <i>bias</i> e $\mathbf{y}_k$ a saída do neurônio $\mathbf{k}$ (HAYKIN, 2001 - Adaptada).	35
Figura 4.12 – Diferenças entre um problema linearmente separável e outro não-linearmente separável (OLIVEIRA, 2004).	45
Figura 4.13 – Esquematização de uma rede <i>perceptron</i> multicamadas.	47
Figura 4.14 – Fase <i>forward</i> e <i>backward</i> do treinamento de retropropagação (THOMÉ e OLIVEIRA, 2004).	47
Figura 5.1 – Retificadora cilíndrica modelo RUAP 515 H, <i>SULMECÂNICA</i>	53
Figura 5.2 – Fontes e unidade de tratamento de sinal de emissão acústica.	54
Figura 5.3 – Fixação do <i>encoder</i> no eixo do motor do cabeçote porta-rebolo.	55
Figura 5.4 – <i>Curvopower</i> ou medidor de potência.	55
Figura 5.5 – Vista da central de aquisição de dados do LUA.	56
Figura 5.6 – Rebolo de CBN 14A1, de especificação SNB151Q12VR2.	57
Figura 5.7 – Dimensões do corpo de prova.	58
Figura 5.8 – Curva de calibração da rotação.	60
Figura 5.9 – Curva de calibração do módulo de potência (<i>curvopower</i>).	61
Figura 5.10 – Fixação do sensor de emissão acústica na contra-ponta da máquina retificadora.	63
Figura 5.11 – Tela principal do programa de aquisição de dados (VI).	64
Figura 5.12 – Disposição dos equipamentos para a medição da rugosidade (R_a).	65
Figura 5.13 – Equipamento TALYROND 31C, do fabricante <i>TAYLOR HOBSON</i>	65
Figura 5.14 – Vista da fixação e medição do erro de circularidade.	66
Figura 5.15 – Região das medições de circularidade e rugosidade.	66

Figura 5.16 – Representação esquemática da medição do desgaste radial do rebolo.	67
Figura 5.17 – Desenho esquemático dos defletores utilizados nos ensaios preliminares.	68
Figura 5.18 – Gráfico de força tangencial de corte utilizando óleo emulsionado.....	69
Figura 5.19 – Gráfico de força tangencial de corte utilizando fluido sintético.....	69
Figura 5.20 – Gráfico de energia específica de retificação utilizando óleo emulsionado.....	70
Figura 5.21 – Gráfico de energia específica de retificação utilizando fluido sintético.....	70
Figura 5.22 – Bocal de 3 mm de diâmetro de saída (dimensões básicas).....	73
Figura 5.23 – Posição do defletor de 0° e do bocal em relação ao rebolo.	73
Figura 5.24 – Aparelhos (a) peagâmetro portátil e (b) refratômetro manual.	74
Figura 5.25 – Fluxograma dos ensaios definitivos (velocidades em milímetros por minuto).	75
Figura 5.26 – Medidor de vazão DMY-2030, da marca CONTECH.....	76
Figura 5.27 – Ensaio sendo realizado na primeira região do corpo de prova.	77
Figura 5.28 – Variáveis utilizadas como dados de entrada e saída da RNA.....	79
Figura 5.29 – Grupos de dados de entrada da RNA.	79
Figura 5.30 – Diferença entre a base de dados A e B	80
Figura 5.31 – Exemplo de treinamento para RNA com base de dados A	86
Figura 5.32 – Configuração final das redes neurais artificiais: (a) MLP-A_I-4x11x2 ; (b) MLP-A_{II}-5x8x2 ; e (c) MLP-A_{III}-6x9x2	87
Figura 5.33 – Configuração final das redes neurais artificiais: (a) MLP-B_I-4x11x2 ; (b) MLP-B_{II}-5x12x2 ; e (c) MLP-B_{III}-6x10x2	88
Figura 6.1 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,1 mm/min.	91
Figura 6.2 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,2 mm/min.	92
Figura 6.3 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,3 mm/min.	92
Figura 6.4 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,4 mm/min.	93
Figura 6.5 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,5 mm/min.	93
Figura 6.6 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,6 mm/min.	94
Figura 6.7 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,7 mm/min.	94
Figura 6.8 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,8 mm/min.	95
Figura 6.9 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,9 mm/min.	95
Figura 6.10 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,0 mm/min.	96
Figura 6.11 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,25 mm/min.	96
Figura 6.12 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,5 mm/min.	97
Figura 6.13 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,75 mm/min.	97
Figura 6.14 – Força tangencial de corte para a velocidade de avanço (V_f) de 2,0 mm/min.	98
Figura 6.15 – Valor médio da força tangencial de corte para todas as velocidades de avanço.....	99
Figura 6.16 – Energia específica para a velocidade de avanço (V_f) de 0,1 mm/min.	101
Figura 6.17 – Energia específica para a velocidade de avanço (V_f) de 0,2 mm/min.	101
Figura 6.18 – Energia específica para a velocidade de avanço (V_f) de 0,3 mm/min.	102
Figura 6.19 – Energia específica para a velocidade de avanço (V_f) de 0,4 mm/min.	102
Figura 6.20 – Energia específica para a velocidade de avanço (V_f) de 0,5 mm/min.	103

Figura 6.21 – Energia específica para a velocidade de avanço (V_f) de 0,6 mm/min.	103
Figura 6.22 – Energia específica para a velocidade de avanço (V_f) de 0,7 mm/min.	104
Figura 6.23 – Energia específica para a velocidade de avanço (V_f) de 0,8 mm/min.	104
Figura 6.24 – Energia específica para a velocidade de avanço (V_f) de 0,9 mm/min.	105
Figura 6.25 – Energia específica para a velocidade de avanço (V_f) de 1,0 mm/min.	105
Figura 6.26 – Energia específica para a velocidade de avanço (V_f) de 1,25 mm/min.	106
Figura 6.27 – Energia específica para a velocidade de avanço (V_f) de 1,5 mm/min.	106
Figura 6.28 – Energia específica para a velocidade de avanço (V_f) de 1,75 mm/min.	107
Figura 6.29 – Energia específica para a velocidade de avanço (V_f) de 2,0 mm/min.	107
Figura 6.30 – Valor médio da energia específica de retificação para todas as velocidades de avanço.	108
Figura 6.31 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,1 mm/min.	109
Figura 6.32 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,2 mm/min.	110
Figura 6.33 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,3 mm/min.	110
Figura 6.34 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,4 mm/min.	111
Figura 6.35 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,5 mm/min.	111
Figura 6.36 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,6 mm/min.	112
Figura 6.37 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,7 mm/min.	112
Figura 6.38 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,8 mm/min.	113
Figura 6.39 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,9 mm/min.	113
Figura 6.40 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,0 mm/min.	114
Figura 6.41 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,25 mm/min.	114
Figura 6.42 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,5 mm/min.	115
Figura 6.43 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,75 mm/min.	115
Figura 6.44 – Emissão acústica RMS para a velocidade de avanço (V_f) de 2,0 mm/min.	116
Figura 6.45 – Valor médio da emissão acústica RMS para todas as velocidades de avanço.	117
Figura 6.46 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,1 mm/min.	118
Figura 6.47 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,2 mm/min.	118
Figura 6.48 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,3 mm/min.	119
Figura 6.49 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,4 mm/min.	119
Figura 6.50 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,5 mm/min.	120
Figura 6.51 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,6 mm/min.	120
Figura 6.52 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,7 mm/min.	121
Figura 6.53 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,8 mm/min.	121
Figura 6.54 – Parâmetro DPO para a velocidade de avanço (V_f) de 0,9 mm/min.	122
Figura 6.55 – Parâmetro DPO para a velocidade de avanço (V_f) de 1,0 mm/min.	122
Figura 6.56 – Parâmetro DPO para a velocidade de avanço (V_f) de 1,25 mm/min.	123
Figura 6.57 – Parâmetro DPO para a velocidade de avanço (V_f) de 1,5 mm/min.	123
Figura 6.58 – Parâmetro DPO para a velocidade de avanço (V_f) de 1,75 mm/min.	124
Figura 6.59 – Parâmetro DPO para a velocidade de avanço (V_f) de 2,0 mm/min.	124

Figura 6.60 – Valor médio do parâmetro DPO para todas as velocidades de avanço.....	125
Figura 6.61 – Média do desgaste diametral para todas as velocidades de avanço.....	126
Figura 6.62 – Média da rugosidade para todas as velocidades de avanço.	128
Figura 6.63 – Média do desvio de circularidade para todas as velocidades de avanço.	129
Figura 6.64 – Regressão linear da média das saídas para a MLP – A_I – 4x4x2	131
Figura 6.65 – Regressão linear da média das saídas para a MLP – A_I – 4x5x2	131
Figura 6.66 – Regressão linear da média das saídas para a MLP – A_I – 4x6x2	131
Figura 6.67 – Regressão linear da média das saídas para a MLP – A_I – 4x7x2	132
Figura 6.68 – Regressão linear da média das saídas para a MLP – A_I – 4x8x2	132
Figura 6.69 – Regressão linear da média das saídas para a MLP – A_I – 4x9x2	132
Figura 6.70 – Regressão linear da média das saídas para a MLP – A_I – 4x10x2	133
Figura 6.71 – Regressão linear da média das saídas para a MLP – A_I – 4x11x2	133
Figura 6.72 – Regressão linear da média das saídas para a MLP – A_I – 4x12x2	133
Figura 6.73 – Regressão linear da média das saídas para a MLP – A_{II} – 5x4x2	136
Figura 6.74 – Regressão linear da média das saídas para a MLP – A_{II} – 5x5x2	136
Figura 6.75 – Regressão linear da média das saídas para a MLP – A_{II} – 5x6x2	137
Figura 6.76 – Regressão linear da média das saídas para a MLP – A_{II} – 5x7x2	137
Figura 6.77 – Regressão linear da média das saídas para a MLP – A_{II} – 5x8x2	137
Figura 6.78 – Regressão linear da média das saídas para a MLP – A_{II} – 5x9x2	138
Figura 6.79 – Regressão linear da média das saídas para a MLP – A_{II} – 5x10x2	138
Figura 6.80 – Regressão linear da média das saídas para a MLP – A_{II} – 5x11x2	138
Figura 6.81 – Regressão linear da média das saídas para a MLP – A_{II} – 5x12x2	139
Figura 6.82 – Regressão linear da média das saídas para a MLP – A_{III} – 6x4x2	141
Figura 6.83 – Regressão linear da média das saídas para a MLP – A_{III} – 6x5x2	141
Figura 6.84 – Regressão linear da média das saídas para a MLP – A_{III} – 6x6x2	141
Figura 6.85 – Regressão linear da média das saídas para a MLP – A_{III} – 6x7x2	142
Figura 6.86 – Regressão linear da média das saídas para a MLP – A_{III} – 6x8x2	142
Figura 6.87 – Regressão linear da média das saídas para a MLP – A_{III} – 6x9x2	142
Figura 6.88 – Regressão linear da média das saídas para a MLP – A_{III} – 6x10x2	143
Figura 6.89 – Regressão linear da média das saídas para a MLP – A_{III} – 6x11x2	143
Figura 6.90 – Regressão linear da média das saídas para a MLP – A_{III} – 6x12x2	143
Figura 6.91 – Regressão linear da média das saídas para a MLP – B_I – 4x4x2	145
Figura 6.92 – Regressão linear da média das saídas para a MLP – B_I – 4x5x2	146
Figura 6.93 – Regressão linear da média das saídas para a MLP – B_I – 4x6x2	146
Figura 6.94 – Regressão linear da média das saídas para a MLP – B_I – 4x7x2	146
Figura 6.95 – Regressão linear da média das saídas para a MLP – B_I – 4x8x2	147
Figura 6.96 – Regressão linear da média das saídas para a MLP – B_I – 4x9x2	147
Figura 6.97 – Regressão linear da média das saídas para a MLP – B_I – 4x10x2	147
Figura 6.98 – Regressão linear da média das saídas para a MLP – B_I – 4x11x2	148
Figura 6.99 – Regressão linear da média das saídas para a MLP – B_I – 4x12x2	148

Figura 6.100 – Regressão linear da média das saídas para a MLP – B_{II} – 5x4x2	150
Figura 6.101 – Regressão linear da média das saídas para a MLP – B_{II} – 5x5x2	150
Figura 6.102 – Regressão linear da média das saídas para a MLP – B_{II} – 5x6x2	151
Figura 6.103 – Regressão linear da média das saídas para a MLP – B_{II} – 5x7x2	151
Figura 6.104 – Regressão linear da média das saídas para a MLP – B_{II} – 5x8x2	151
Figura 6.105 – Regressão linear da média das saídas para a MLP – B_{II} – 5x9x2	152
Figura 6.106 – Regressão linear da média das saídas para a MLP – B_{II} – 5x10x2	152
Figura 6.107 – Regressão linear da média das saídas para a MLP – B_{II} – 5x11x2	152
Figura 6.108 – Regressão linear da média das saídas para a MLP – B_{II} – 5x12x2	153
Figura 6.109 – Regressão linear da média das saídas para a MLP – B_{III} – 6x4x2	154
Figura 6.110 – Regressão linear da média das saídas para a MLP – B_{III} – 6x5x2	154
Figura 6.111 – Regressão linear da média das saídas para a MLP – B_{III} – 6x6x2	155
Figura 6.112 – Regressão linear da média das saídas para a MLP – B_{III} – 6x7x2	155
Figura 6.113 – Regressão linear da média das saídas para a MLP – B_{III} – 6x8x2	155
Figura 6.114 – Regressão linear da média das saídas para a MLP – B_{III} – 6x9x2	156
Figura 6.115 – Regressão linear da média das saídas para a MLP – B_{III} – 6x10x2	156
Figura 6.116 – Regressão linear da média das saídas para a MLP – B_{III} – 6x11x2	156
Figura 6.117 – Regressão linear da média das saídas para a MLP – B_{III} – 6x12x2	157
Figura 6.118 – Regressão linear dos resultados da RNA MLP – A_I – 4x11x2	158
Figura 6.119 – Regressão linear dos resultados da RNA MLP – A_{II} – 5x8x2	159
Figura 6.120 – Regressão linear dos resultados da RNA MLP – A_{III} – 6x9x2	159
Figura 6.121 – Regressão linear dos resultados da RNA MLP – B_I – 4x11x2	160
Figura 6.122 – Regressão linear dos resultados da RNA MLP – B_{II} – 5x12x2	161
Figura 6.123 – Regressão linear dos resultados da RNA MLP – B_{III} – 6x10x2	161

LISTA DE TABELAS

Tabela 4.1 – Propriedades de alguns materiais abrasivos (MALKIN, 1989).	20
Tabela 4.2 – Tipos de funções de ativação e suas representações gráficas.....	38
Tabela 5.1 – Composição química do aço VC-131 em % (KNIFECO, 2004).	57
Tabela 5.2 – Disposição dos ensaios de usinagem.	75
Tabela 5.3 – Base de dados A com 14 conjuntos (um para cada V_f).	81
Tabela 5.4 – Base de dados B com 560 conjuntos (40 para cada V_f).	82
Tabela 5.5 – RNA's que foram utilizadas neste trabalho.	82
Tabela 5.6 – Disposição dos dados de treinamento e validação da base de dados A	84
Tabela 5.7 – Exemplo da distribuição dos dados de treinamento e validação da base de dados B para cada velocidade de avanço.	84
Tabela 5.8 – Parâmetros utilizados na escolha da camada oculta de cada RNA.	85
Tabela 6.1 – Erros (%) dos valores médios das saídas das RNA's A_I	135
Tabela 6.2 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's A_I	135
Tabela 6.3 – Erros (%) dos valores médios das saídas das RNA's A_{II}	139
Tabela 6.4 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's A_{II}	140
Tabela 6.5 – Erros (%) dos valores médios das saídas das RNA's A_{III}	144
Tabela 6.6 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's A_{III}	144
Tabela 6.7 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's B_I	149
Tabela 6.8 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's B_{II}	153
Tabela 6.9 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's B_{III}	157
Tabela 6.10 – Média dos erros (%) dos resultados para as configurações finais das RNA's.	162

LISTA DE ABREVIATURAS E SÍMBOLOS

a - penetração de retificação	[mm]
a_d - penetração de dressagem	[μm]
Al₂O₃ - óxido de alumínio	
a_t - penetração do rebolo para medição do desgaste diametral	[μm]
b - largura de retificação	[mm]
b_d - largura de trabalho do dressador	[μm]
b_s - largura do rebolo	[mm]
CBN - nitreto cúbico de boro	
CNC - comando numérico computadorizado	
C_r - razão de contração	
D - diâmetro da mangueira de alimentação do fluido	[mm]
D_n - diâmetro de saída do bocal	[mm]
DPO - multiplicação entre o desvio-padrão do sinal RMS de emissão acústica e a potência elétrica média por passada do rebolo (ciclo)	
d_s - diâmetro do rebolo	[mm]
d_w - diâmetro da peça	[mm]
EA - emissão acústica	[V]
F_n - força normal de corte	[N]
F_t - força tangencial de corte	[N]
G - relação entre o volume de material removido e o volume do rebolo gasto	
h - profundidade de corte crítica	[μm]
I_a - corrente do motor de acionamento do rebolo	[V]
k - representação do neurônio	
l_c - comprimento de contato	[mm]
MLP - <i>perceptron</i> de múltiplas camadas	
n_s - velocidade ou rotação crítica do rebolo	[rpm]
n_w - rotação da peça	[rpm]
O - símbolo adotado para o desvio (ou erro) de circularidade	[μm]
P - potência mecânica de retificação	[W]
P_{el} - potência elétrica do circuito condicionador de sinais	[W]
P_{MED} - potência elétrica média em um ciclo	[W]
Pt - distância vertical entre o pico mais alto e o vale mais baixo do degrau	[μm]
Q_w - taxa de remoção volumétrica	[mm ³ /s]
R - coeficiente de correlação linear	
r - taxa real de avanço	
r₁ - posição ideal do rebolo após o fim do avanço	
r₂ - posição real do rebolo após o fim do avanço	

R_a - rugosidade aritmética	[μm]
RNA - rede neural artificial	
RNA's - redes neurais artificiais	
RMS - <i>root mean square</i>	
RPM - rotação do rebolo	[rpm]
S_{EA} - desvio-padrão da emissão acústica	
sgn - função sinal	
SiC - carbeto de silício	
t_c - tempo de centelhamento	[s]
u - energia específica de retificação	[J/mm ³]
u₁ - taxa de avanço	
u₂ - taxa de avanço no período de <i>spark-out</i> nulo	
u_{ch} - energia referente à formação do cavaco	[J/mm ³]
u_{pl} - energia utilizada na deformação do material	[J/mm ³]
u_{sl} - energia referente ao deslizamento	[J/mm ³]
u_t - energia específica total de retificação para o corte	[J/mm ³]
V - tensão de saída do motor de acionamento do rebolo	[V]
V_f - velocidade de avanço ou mergulho	[mm/min]
V_{fd} - velocidade de penetração de dressagem	[mm/min]
V_j - velocidade do jato de fluido de corte	[m/s]
V_s - velocidade tangencial (ou periférica) do rebolo	[m/s]
V_{sd} - velocidade de avanço de dressagem	[mm/min]
V_w - velocidade tangencial (ou periférica) da peça	[m/s]
w - vetor peso das sinapses	
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 - momentum	
ΔR - defasagem da posição do rebolo	
Δ_r - desgaste radial do rebolo	[μm]
ΔØ - desgaste diametral do rebolo	[μm]
ε - diferença final entre a posição do rebolo pré-estabelecida e a real do ciclo	
η - taxa de aprendizado	
φ - função de ativação de um neurônio	
θ_k - <i>bias</i> de um neurônio	

RESUMO

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. Desta forma, estudou-se neste trabalho os assuntos relacionados à aplicação das redes neurais na predição da circularidade e rugosidade da peça retificada pela análise de algumas variáveis de saída do processo. Foram empregados nos ensaios de usinagem: um fluido de corte (óleo emulsionável), um rebolo superabrasivo de CBN com ligante vitrificado e peças temperadas e revenidas de aço VC-131. Este trabalho também utilizou outras tecnologias de otimização do processo de retificação, tais como: a utilização de defletores aerodinâmicos para a quebra da camada de ar e a refrigeração otimizada por meio de um jato de fluido direcionado. Os ensaios de usinagem foram realizados para gerar a base de dados utilizada nos testes das redes neurais (ensaios computacionais). Fez-se portanto, diversos experimentos variando-se a velocidade de avanço, ou mergulho do rebolo na peça. As variáveis de saída analisadas que serviram de dados de entrada para a RNA foram: a força tangencial de corte (F_t), a energia específica de retificação (u), o desgaste diametral do rebolo, o parâmetro **DPO** e a emissão acústica (**EA**). A rugosidade e circularidade foram utilizadas para o treinamento das RNA's. Nos testes computacionais, foram analisadas duas bases de dados: a primeira referente às médias de todos os 40 ciclos de retificação, já a segunda utilizou todos os valores destes 40 ciclos. Ainda foram examinadas diferentes combinações de dados de entrada para verificar a influência do parâmetro **DPO** na predição. Os resultados obtidos mostraram que este parâmetro não foi capaz de substituir a força tangencial de corte e a emissão acústica na predição. Além disso, notou-se a necessidade da utilização de uma entrada que representasse a rigidez dinâmica do sistema máquina-ferramenta-peça para o menor erro na predição da circularidade. Outra conclusão importante é a possibilidade de se utilizar a segunda base de dados citada no controle do processo por meio de tecnologia de arquitetura aberta.

Palavras-chave: Retificação; Redes Neurais Artificiais; Predição; Rugosidade; Circularidade.

ABSTRACT

Nowadays, the manufacturing is characterized by its complexity, plurality of subjects and increasing demand of new tools and techniques for the solution of difficult problems. Artificial neural nets propose a new and different alternative to investigate and analyze the challenging topics related to the manufacturing. The objective of this work is to study the use of artificial neural nets in the prediction of roundness and roughness of a ground workpiece. It was used a CBN wheel, emulsion oil and workpieces made of VC-131 steel. This work also used other technologies of grinding optimization, such as: the use of a coolant shoe to break the air curtain layer in addition and the high pressure fluid jet. Grinding tests had been carried through to generate the database used in the artificial neural nets (computational tests). Different feed rates were used in these experiments to generate outputs such as: tangential cutting force (F_t), specific energy of grinding (u), diametrical wear of the wheel, **DPO** parameter and acoustic emission (**EA**). The roughness and roundness were used to train the RNA's. In the computational tests, it was verify the influence of the **DPO** parameter in the prediction as well as two different databases. The results suggest that this parameter (**DPO**) was not able to substitute the tangential cutting force (F_t) and the acoustic emission (**EA**) in the prediction. Moreover, it was verify the need of an input that represents the dynamic stiffness of the machine-tool-workpiece system to improve the roundness prediction.

Keywords: Grinding; Artificial Neural Net; Prediction; Roughness; Roundness.

1 INTRODUÇÃO

A retificação tem sido uma das mais importantes técnicas usadas para obter peças de alta precisão, sendo responsável por uma considerável parcela do total de operações de usinagem nos países industrializados.

Um grande número de componentes manufaturados são usinados pela retificação ou são processados por máquinas cuja precisão foi obtida por operações abrasivas (MALKIN, 1989). Sabe-se que melhoramentos no processo conduzem a uma maior precisão, produção mais rápida e redução de custos.

Dentre as possibilidades de melhoramento da retificação, pode-se citar a aplicação deste processo associado aos conceitos e práticas da inteligência artificial, a qual se refere à capacidade de uma máquina executar tarefas normalmente associadas ao intelecto humano, tais como: o raciocínio, o aprendizado e o automelhoramento (ROWE et al., 1996).

Dentre as técnicas mais conhecidas da inteligência artificial, encontram-se as redes neurais artificiais (RNA's), que são modelos computacionais análogos ao cérebro humano e possuem como principal característica a capacidade de aprendizado.

Esta característica pode ser de grande utilidade quando empregada no processo de retificação, pois este procedimento nem sempre origina resultados adequados, já que existe um enorme número de fatores que o influenciam, fazendo com que um resultado reproduzível seja dificilmente alcançado (INASAKI e OKAMURA, 1985).

A predição de parâmetros da peça é uma possibilidade de aproveitamento destas duas tecnologias. Existem poucos estudos referentes à predição de circularidade e rugosidade de peças retificadas. Portanto, este trabalho tem a pretensão de adicionar tópicos de discussão a esta aplicação em especial.

1.1 ESTRUTURA DO TRABALHO

No capítulo 1 é apresentada uma introdução geral sobre o processo de retificação e as aplicações da inteligência artificial nos processos de fabricação.

O capítulo 2 exprime o objetivo do projeto e o capítulo 3 contém as justificativas para a realização desta pesquisa científica.

A revisão de literatura começa no capítulo 4, no qual são apresentados os principais parâmetros e variáveis que fazem parte do processo de retificação cilíndrica externa de

mergulho. Neste capítulo também é apresentada a revisão bibliográfica referente às Redes Neurais Artificiais e suas aplicações.

No capítulo 5 é descrita a metodologia que foi empregada neste trabalho bem como os materiais e equipamentos utilizados.

Já no capítulo 6 são apresentados os resultados e discussões pertinentes a este trabalho científico.

O capítulo 7 apresenta as conclusões do mesmo, assim como algumas sugestões para trabalhos futuros. Por fim, na sequência são apresentadas as referências bibliográficas que foram utilizadas para a redação desta Dissertação de Mestrado.

2 OBJETIVO

Este trabalho tem como objetivo, o estudo das redes neurais artificiais aplicadas no processo de retificação para a predição da rugosidade e circularidade da peça.

Estas características finais das peças retificadas (circularidade e rugosidade) são extremamente importantes na produção de componentes mecânicos.

Deste modo, iniciou-se um estudo no qual foi observada a influência de:

- ❖ duas bases de dados distintas na predição;
- ❖ diferentes combinações de redes neurais artificiais; e
- ❖ diferentes variáveis de entrada na qualidade da predição.

Com isto, pretendeu-se definir alguns parâmetros que poderão servir de base para a utilização das Redes Neurais Artificiais no processo de retificação cilíndrica externa.

3 JUSTIFICATIVAS PARA A REALIZAÇÃO DESTA PESQUISA

A justificativa para a realização deste trabalho é a crescente demanda de novas ferramentas e técnicas nos processos produtivos. Em especial, a utilização de um conhecimento extremamente novo e de grande potencial como a inteligência artificial, em um processo com uma grande quantidade de variáveis, e portanto de alta complexidade como a retificação.

O processo de retificação pode se beneficiar desta ferramenta de predição pela diminuição do número de medições da circularidade e rugosidade, diminuindo assim o tempo gasto na análise da qualidade da peça e conseqüentemente os custos finais.

Este trabalho torna-se também importante e justificável, pois será mais uma fonte de consultas para o contínuo desenvolvimento da aplicação de Redes Neurais Artificiais no processo de retificação. Deste modo, pretende-se acrescentar à literatura, conceitos importantes sobre o referido tópico de estudo de forma a enriquecer o conhecimento científico nacional e internacional.

4 REVISÃO BIBLIOGRÁFICA

O presente capítulo tem a finalidade de apresentar a bibliografia fundamental referente aos assuntos que são abordados nesta pesquisa.

Este trabalho explora dois campos do conhecimento humano: a engenharia mecânica caracterizada pelo processo de retificação e a inteligência artificial representada pelas redes neurais artificiais, que são modelos computacionais análogos ao funcionamento do cérebro humano. Portanto, esta pesquisa terá como ponto de partida o estudo do processo de retificação, especificamente a retificação cilíndrica externa e seus assuntos correlatos. Posteriormente, será feito um estudo sobre a Rede Neural Artificial (RNA) e sua aplicação na usinagem de materiais.

4.1 A RETIFICAÇÃO CILÍNDRICA EXTERNA

O processo de retificação é considerado um dos mais importantes da manufatura, pois quase todos os produtos industrializados possuem componentes que foram concebidos a partir deste processo ou a partir de máquinas que possuem a sua precisão graças à retificação (MALKIN, 1989).

Este processo visa melhorar o acabamento superficial e garantir a integridade das peças (VIEIRA JÚNIOR et al., 1999). Trata-se de um processo de alta precisão e importância, já que é inaceitável perder uma peça nesta etapa, pois o valor agregado ao material nesta fase já é muito elevado devido aos outros processos que antecederam o mesmo (SOARES e OLIVEIRA, 2002).

Além disso, a retificação é um processo bastante complexo, pois envolve uma gama de parâmetros e variáveis que influenciam no processo, tais como tipos de fluidos de corte, rebolos e parâmetros como velocidades de corte e de avanço etc. Portanto, para se controlar melhor a retificação é necessário analisar o maior número de variáveis possíveis, evitando assim perdas de peças durante o processo.

A operação de retificação cilíndrica externa de mergulho, a qual foi utilizada neste trabalho, pode ser visualizada na Figura 4.1.




Figura 4.1 – Caracterização do processo de retificação cilíndrica externa de mergulho (MALKIN, 1989 - Adaptada).

De acordo com a Figura 4.1, tem-se que a operação de retificação cilíndrica externa de mergulho consiste, basicamente, na penetração de retificação a correspondente ao final do ciclo de retificação, com velocidade tangencial do rebolo V_s , velocidade de mergulho V_f , velocidade tangencial da peça V_w , diâmetro da ferramenta d_s , diâmetro da peça d_w , comprimento de contato l_c força tangencial de corte F_t e força normal de corte F_n . A correlação entre estes parâmetros caracteriza a operação de retificação cilíndrica externa de mergulho.

De acordo com OLIVEIRA (1989), o ciclo de retificação é entendido como o conjunto de etapas que ocorrem em uma operação, desde a colocação da peça na máquina até a saída desta dentro de especificações pré-determinadas. O ciclo de retificação é subdividido em fases, e cada uma possui um tempo para sua execução. Exemplos destas fases podem ser:

- ❖ Aproximação;
- ❖ Mergulho do rebolo na peça;
- ❖ *Spark-out* ou centelhamento;
- ❖ Recuo do rebolo; e
- ❖ Troca da peça e dressagem da ferramenta (se necessário).

No começo da operação de retificação cilíndrica de mergulho, o rebolo, ao iniciar o seu avanço sobre a peça (início do corte), gera uma força normal proporcional a esta taxa de avanço que, por sua vez, gera uma deformação no conjunto máquina-ferramenta-rebolo. Esta deformação causa uma deflexão do sistema de forma que, ao final da primeira volta da ferramenta, o rebolo que deveria estar em uma posição r_2 , está, na realidade, em uma posição r_1 anterior a esta, ou seja, defasado em relação à posição desejada.

Pode-se concluir portanto, que para uma operação de retificação qualquer, deve-se deixar o rebolo usinando, sem avanço, para que este possa chegar à posição desejada. Esta operação é chamada de *spark-out*, ou tempo de centelhamento. A Figura 4.2 exhibe o *spark-out* no ciclo de retificação de mergulho, onde: u_1 é a taxa de avanço, r a taxa de avanço real, u_2 a taxa de avanço no período de *spark-out* (nulo), t_c o tempo de centelhamento, ΔR a defasagem da posição do rebolo e ϵ a diferença final entre a posição pré-estabelecida e a real do ciclo (MALKIN, 1989).




Figura 4.2 – *Spark-out* no ciclo de retificação cilíndrica de mergulho (MALKIN, 1989 - Adaptada).

A soma de todos os tempos das fases descritas acima, resulta no tempo total de retificação, que é um parâmetro muito importante na produção em massa.

4.1.1 Variáveis de Saída

Alguns exemplos de variáveis de saídas obtidas do processo de retificação que serão vistas a seguir, são:

- ❖ Força tangencial de corte (F_t);
- ❖ Energia específica de retificação (u);
- ❖ Parâmetro **DPO**;
- ❖ Emissão acústica (**EA**);
- ❖ Circularidade;
- ❖ Rugosidade; e
- ❖ Desgaste diametral do rebolo ($\Delta\emptyset$).

4.1.1.1 Força tangencial de corte (F_t) e energia específica de retificação (u)

O estudo da força de corte na retificação é um tópico de extrema importância. No projeto e dimensionamento da retificadora e de seus componentes, as forças de corte são parâmetros que determinam, tanto a potência motriz do rebolo como as necessidades estruturais da máquina. Deste modo, com o auxílio de métodos numéricos pode ser calculada a rigidez da estrutura e com as forças de corte podem ser previstas as deformações sofridas. Já, para o processo de corte, as forças de corte causam influências na qualidade dimensional e geométrica do produto acabado, na rugosidade, no desgaste do rebolo e também no tempo de retificação (OLIVEIRA, 1989).

Portanto, é de extrema importância que tais forças possam ser previamente conhecidas, pois, as mesmas fornecem os dados necessários, tanto para o projeto de novas máquinas e componentes, quanto para o conhecimento do fenômeno de corte do processo de retificação, objetivando o seu contínuo aperfeiçoamento tecnológico.

As forças de corte na retificação dependem de inúmeros fatores como:

- ❖ Tipo do rebolo;
- ❖ Condições de corte;
- ❖ Condições de afiação da ferramenta;
- ❖ Material utilizado;
- ❖ Fluido de corte;
- ❖ Tipo de refrigeração utilizada etc.

Deste modo, esta grandeza está sujeita a grandes variações com a mudança de qualquer um destes fatores, o que torna a retificação extremamente complexa quando comparada a outros processos de fabricação (OLIVEIRA, 1989).

Segundo MALKIN (1989), as forças são desenvolvidas na interface rebolo-ferramenta devido à ação do processo de retificação. Para a retificação cilíndrica externa de mergulho, o vetor resultante da força total exercida pela peça sobre o rebolo pode ser decomposto em uma componente de força tangencial (F_t) e uma componente de força normal (F_n).

A potência de retificação (P) pode ser escrita da seguinte forma:

$$P = F_t (V_s \pm V_w) \quad (4.1)$$

Onde:

V_s é a velocidade tangencial do rebolo; e

V_w é a velocidade tangencial da peça.

O sinal de positivo na Equação 4.1 é empregado na retificação discordante (V_s e V_w têm direções opostas durante a operação) e o sinal negativo é utilizado para retificação concordante, com ambas as velocidades na mesma direção. Como V_w é, usualmente, muito menor que V_s , a potência (P) pode ser escrita como:

$$P = F_t V_s \quad (4.2)$$

Um parâmetro fundamental derivado da potência (P) e das condições de usinagem é a energia específica de retificação (u), expressa em J/mm^3 , a qual é obtida pela Equação 4.3:

$$u = \frac{P}{Q_w} \quad (4.3)$$

Onde:

Q_w é a taxa de remoção volumétrica [mm^3/s], a qual é definida como:

$$Q_w = V_w ab = \pi d_w V_f b \quad (4.4)$$

Onde:

a é a penetração de retificação;

b é a largura de retificação;

V_f é a velocidade de mergulho; e

d_w é o diâmetro da peça.

Um estudo mais aprofundado a respeito da energia específica de retificação será apresentado no item 4.1.2.3, referente à formação do cavaco.

4.1.1.2 Emissão acústica (EA) e o parâmetro DPO

A emissão acústica (EA) pode ser definida como sendo ondas de tensões elásticas geradas como 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 piezoelétrico que transforma estes deslocamentos em sinais elétricos (DINIZ et al., 1991).

Sua faixa de frequência gira em torno de 50 kHz a 1.000 kHz, que está acima da faixa de muitos ruídos vindo de fontes exteriores ao próprio processo de retificação. Sendo assim, é um método sensível e adequado para monitorar o processo de retificação (KLUFT, 1994).

WEBSTER et al. (1994) afirma 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 fornece uma técnica mais promissora para o monitoramento *on-line* do processo.

As origens da emissão acústica no processo são decorrentes principalmente da fratura do grão e do ligante, e fricção entre o grão abrasivo e a peça, todos diretamente ligados ao processo de formação de cavaco e desgaste do rebolo (BIFFI, 2003), como pode ser verificado na Figura 4.3. Com o sinal de emissão acústica é possível, por exemplo, determinar o fim do *spark-out*, que é muito importante para diminuir o tempo do ciclo de retificação (OLIVEIRA, 1998).




Figura 4.3 – Origem do sinal de emissão acústica no processo de retificação (BIFFI, 2003 - Adaptada).

Nos primeiros trabalhos referentes à utilização da emissão acústica para a monitoração da retificação, a técnica era utilizada, basicamente, para detectar a ocorrência do contato entre a peça e o rebolo (DORNFELD e CAI, 1984 e INASAKI e OKAMURA, 1985). A dressagem também era monitorada e o sinal de emissão acústica servia para verificar a uniformidade da passada, indicando assim, o final da dressagem.

Após isso, a aplicação da emissão acústica teve um grande salto e surgiram diversos estudos que tentaram relacionar sinais de emissão acústica a aspectos relativamente complicados do processo de retificação, incluindo a detecção de quebra, queima e trincas e a transição do modo dúctil/frágil (BIFANO e YI, 1992).

O parâmetro predominantemente estudado em pesquisas prévias usando emissão acústica vem sendo o valor médio quadrático (RMS) do sinal de EA filtrado (EA_{RMS}) sobre uma banda de frequência cuidadosamente selecionada. Este 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.

AGUIAR (1997) demonstrou que a combinação do sinal RMS de emissão acústica e do sinal de potência elétrica do motor podem fornecer parâmetros expressivos para a indicação da queima da peça na retificação plana. Da combinação entre os sinais, obteve-se 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 elétrica média por passada do rebolo (ciclo). Este parâmetro é atualmente um dos mais aplicados na detecção da queima. A Equação 4.5 exibe o parâmetro **DPO**.

$$DPO = S_{EA} P_{MED} \quad (4.5)$$

Onde:

S_{EA} é o desvio-padrão do nível RMS de emissão acústica; e

P_{MED} é o valor médio da potência elétrica (W).

Um estudo recente expõe um novo método de monitoramento chamado de mapa acústico. Este mapeamento pode ser feito basicamente para três situações, de acordo com VIEIRA JÚNIOR e OLIVEIRA (2002):

- ❖ **Avaliação da dressagem:** Durante a operação de dressagem a interação entre o dressador e o rebolo pode ser mapeada acusticamente. A falta de contato é mostrada como áreas escuras no mapa e a dressagem deve continuar até que toda a área do mapa esteja com o mesmo nível de intensidade. Este mapa mostra em um eixo a intensidade da EA na largura do rebolo e pela sua distância periférica;
- ❖ **Mapeamento topográfico:** Neste caso, o mapa é similar ao obtido na dressagem, no entanto, a profundidade de corte utilizada é próxima de zero. Assim, o mapa mostra a superfície ativa do rebolo, ou seja, a superfície que entrará em contato com a peça no decorrer do processo; e
- ❖ **Avaliação da retificação:** Durante a operação de mergulho do rebolo, a interação ferramenta-peça pode ser avaliada. Neste caso, o mapa acústico é diferente, pois, um eixo é o tempo de retificação e o outro a energia acústica média do processo em toda a largura de retificação e circunferência do rebolo.

O sinal bruto de emissão acústica também está sendo explorado no monitoramento do processo de retificação. Estudos técnicos (JEMIELNIAK, 1997 e WANG et al., 2001) mostram que a utilização de ferramentas de processamento de sinais, juntamente com as redes neurais artificiais, são eficientes no monitoramento da retificação.

4.1.1.3 Circularidade

Segundo JEDRZEJEWSKI e MODRZYCKI (1997), o erro de circularidade pode ser entendido como qualquer divergência entre a peça construída e a peça teoricamente exigida com tolerância especificada.

O erro de circularidade ocasionado pelo processo durante a usinagem (Figura 4.4), está diretamente relacionado com as condições de retificação, os danos térmicos, as solicitações mecânicas, a pressão e a vazão de fluido de corte utilizado. O erro de circularidade expressa qual o erro de forma final da peça usinada, pois em processos de retificação de precisão este fator é muito importante, já que o mesmo indica qual o estado cilíndrico final da peça (FUSSE et al., 2004).




Figura 4.4 – Exemplo de uma peça com erro de circularidade (TAYLOR-HOBSON, 2000).

Para JUNIOR (1996), a retificação é usada em operações de acabamento onde a qualidade do material retificado e os erros de circularidade são importantes e conseqüentemente controlados.

Uma peça nunca é perfeitamente cilíndrica, pois em todas as peças podem estar presentes os erros de circularidade, que é um dos principais causadores desta não perfeição cilíndrica.

O erro de circularidade pode ter origem na própria retificadora. Os componentes das máquinas retificadoras são fabricados por outras máquinas-ferramentas (tornos, fresas,

furadeiras etc.), que também produzem peças com erros de circularidade. Portanto, é muito provável que este erro seja transferido de uma máquina para outra.

A retificadora também sofre um aumento de temperatura durante o seu funcionamento causado por alguns componentes, tais como: rolamentos e mancais; engrenagens; polias e correias; freios e embreagens; bombas e motores; guias e fusos. Esta elevação de temperatura pode causar distorções na máquina e conseqüentemente erros de circularidade na peça.

A precisão da peça a ser obtida em uma máquina-ferramenta é influenciada pela dilatação térmica em seus elementos de máquinas. Estas dilatações térmicas produzem uma distorção térmica que levam a um deslocamento relativo entre a peça e a ferramenta cortante, gerando assim uma influência na precisão da peça que está sendo submetida à operação.

O perfil final da peça também pode ser afetado pelo perfil inicial da mesma e pelo mau alinhamento do centro da peça cilíndrica (PARK et al., 1999). Isto mostra como é complicado o processo de retificação. Especialmente, a retificação ao longo de eixos delgados, sem paralelismo na direção axial, torna-se um processo delicado devido a deformação elástica dos componentes do rebolo.

Uma causa muito freqüente do erro de circularidade nas peças retificadas é o desbalanceamento do rebolo, o qual é causado por uma massa ou concentração de massa que não é simetricamente distribuída sobre o eixo de rotação. Este desbalanceamento de massa do rebolo irá atritar a peça alternadamente e pode ser pensado como um vetor unidirecional de desequilíbrio de magnitude constante, que gira com o fuso. Este desequilíbrio de massa produz uma peça de perfil geométrico não uniforme, conforme Figura 4.5.




Figura 4.5 – (a) Peça retificada com rebolo balanceado e (b) peça retificada com rebolo desbalanceado.

4.1.1.4 Rugosidade

Segundo AGOSTINHO et al. (1981), a rugosidade são micro-irregularidades geométricas decorrentes do processo de fabricação. Sua quantificação é feita pelos parâmetros de altura e largura das irregularidades, medidos geralmente por perfilômetros de contato mecânico ou rugosímetros.

Os processos de usinagem afetam diretamente a rugosidade da peça e o controle da mesma é feito pelo gerenciamento e otimização dos processos e condições de usinagem. As alterações da rugosidade ocorrem em função do tipo da ferramenta, afiação da ferramenta, condições de usinagem, dentre outros (FUSSE et al., 2004).

O acabamento superficial sofre influência de vários parâmetros de usinagem, incluindo: a geometria da ferramenta de corte, geometria da peça, rigidez da máquina-ferramenta, material da peça, condições de corte, material da ferramenta, dentre outros. (FUSSE et al., 2004).

Normalmente o acabamento superficial melhora com o aumento da velocidade de corte (V_s). A melhora é rápida até uma determinada velocidade crítica, devido à contínua redução das dimensões da aresta de corte efetiva. Depois que esta aresta ficou reduzida a um tamanho insignificante, pouca melhora adicional do acabamento superficial se obtém com aumentos maiores da velocidade de corte (MALKIN, 1989). Um bom acabamento exige avanços menores.

4.1.1.5 Desgaste diametral do rebolo ($\Delta\phi$)

De acordo com MALKIN (1989), o desgaste do rebolo ocorre devido à três causas principais:

- ❖ Fratura do ligante;
- ❖ Fratura do grão; e
- ❖ Atrito entre o grão e a peça.

Estas causas foram exibidas na Figura 4.3, pois também são relacionados com a emissão acústica no processo de retificação.

O desgaste de atrito envolve a perda de afiação do grão abrasivo e o aparecimento de regiões planas nos mesmos. A fratura do grão se refere à fratura que ocorre no corpo do grão abrasivo desprendendo parte deste e gerando novas arestas de corte. Já a fratura do ligante está relacionada ao desprendimento integral do grão abrasivo e este fenômeno é o de maior gravidade no desgaste do rebolo.

LINDSAY (1984) constatou em seu estudo que para uma determinada condição de ensaio onde o desgaste do rebolo é pequeno, com o transcorrer do tempo, o rebolo logo estará sem arestas de corte gerando assim uma elevada força de corte. Do mesmo modo, para uma outra operação na qual o desgaste é grande, o rebolo sempre se encontra agressivo.

Portanto, o que pode ser observado é que idealmente, o desgaste do rebolo é benéfico para o processo. No entanto, não é o que ocorre na maioria das vezes, pois os rebolos perdem afiação e a força de corte não é suficientemente alta para arrancar o grão desgastado ou fraturá-lo para gerar novas arestas de corte, restando por fim, realizar a operação de dressagem.

De acordo com HAHN e LINDSAY (1971 apud OLIVEIRA, 1989), o desempenho do rebolo pode ser avaliado pela relação G (adimensional), definida como sendo a relação entre o volume de material removido (Z_w) e o volume de rebolo gasto (Z_s), conforme a Equação 4.6.

$$G = \frac{Z_w}{Z_s} \quad (4.6)$$

No entanto, neste trabalho será utilizado apenas o valor da perda diametral do rebolo ($\Delta\emptyset$), já que este valor comparativo, serve perfeitamente para os propósitos da implementação da RNA.

4.1.2 Formação do Cavaco

Segundo MALKIN (1989), o mecanismo de formação do cavaco engloba três etapas:

- ❖ deslizamento (*sliding*);
- ❖ deformação plástica sem remoção de material (*plowing*); e
- ❖ a formação do cavaco propriamente dita.

4.1.2.1 Forças de deslizamento

Apesar da remoção de material ocorrer principalmente por formação de cavaco, como relatado anteriormente, uma grande parte da energia de retificação é direcionada a outros mecanismos distintos da formação do cavaco.

Segundo MALKIN (1989), um destes mecanismos pode envolver grãos abrasivos “cegos”, com os topos dos grãos achatados, deslizando contra a peça, sem remover nenhuma quantidade de material. Esta perda da aresta cortante pode ser gerada por processos de dressagem pouco agressivos, por desgaste do grão abrasivo durante o processo de corte ou por adesão do material usinado na superfície do rebolo.

A presença de grãos com área de topo desgastada, caracterizada pelas marcas estriadas observadas na direção de corte e na superfície retificada, indicam que parte da energia gasta na retificação deve-se ao deslizamento dos grãos “cegos” contra a peça.

MALKIN (1989) afirma que existe uma relação direta entre o aumento das forças de retificação (tangencial e normal) com o aumento da área de desgaste do topo dos grãos. A partir de resultados experimentais, para aplicação em aços, as forças de usinagem aumentam linearmente com o aumento do desgaste de área do topo dos grãos, até atingir um ponto crítico, o que ocasiona a queima da peça.

Segundo MALKIN e COOK (1971 apud MALKIN, 1989), as forças de usinagem associadas à energia específica de retificação, podem ser constituídas de componentes como corte e deslizamento, considerando que o desgaste do topo do grão é influenciado pelas condições de dressagem, pela dureza do ligante e pela influência do tipo de fluido de corte utilizado.

4.1.2.2 Plowing e formação do cavaco

A energia específica de retificação para o corte (u), é a parcela remanescente da subtração do valor da energia específica devido ao deslizamento (u_d) do valor total da energia específica de retificação (u_t).

Segundo MALKIN (1989), mesmo após subtrair o valor da energia específica referente ao deslizamento, torna-se aparente que ainda existe um efeito residual. A pequenas taxas específicas de remoção de material, correspondente a pequenas espessuras de cavaco, a energia específica de retificação torna-se extremamente elevada e sua magnitude não pode ser adequada ao modelo clássico de formação do cavaco, porém para maiores valores ocorre uma tendência à um valor mínimo limite de $13,8 \text{ J/mm}^3$. Este modelo afirma que de toda a energia gerada no processo, o cisalhamento do cavaco era responsável pela geração de 75% da energia total e os 25% restantes eram devido ao atrito cavaco-ferramenta.

Este efeito residual observado indica que somente uma parte da energia específica de retificação é realmente associada à formação de cavaco, havendo portanto possibilidade de ocorrer outro mecanismo responsável pela geração da energia remanescente.

O outro mecanismo associado ao processo abrasivo é a deformação plástica sem remoção de material, ou *plowing*, o qual relaciona a energia gasta para a realização desta deformação. Este mecanismo é associado ao escoamento lateral do material, em forma de “cristas”, ao longo do caminho de corte do grão abrasivo, incluindo a deformação plástica do material passando por baixo do gume abrasivo (MALKIN, 1989).

Inicialmente, quando o grão abrasivo entra em contato com o material da peça, este realiza um contato elástico cujo gasto energético é considerado mínimo com relação ao total da energia de corte. Em seguida ocorre a deformação plástica (*plowing*) do material da peça.

Em geral o corte é iniciado quando o grão abrasivo atinge uma profundidade de corte crítica (**h**). Os fatores que afetam a magnitude de (**h**) incluem: o desgaste de área de topo de grão do rebolo (seu grão de afiação), a orientação, ângulo de incidência do grão e o coeficiente de fricção (atrito) (MALKIN, 1989).

Após o início do cisalhamento, o *plowing* pode ainda ocorrer com uma parcela do material escoando, em forma de cristas, ao invés de ser removido em forma de cavaco.

Uma forma de acompanhar o *plowing* é pelo controle da espessura máxima do cavaco, considerando que o aumento desta espessura, permite uma diminuição do material escoado plasticamente, atingindo-se mais rapidamente o valor de (**h**) crítico para início do corte, provocando a diminuição da energia específica de *plowing*. No limite, esta energia tende a zero, aproximando da energia específica de retificação (**u_{ch}**), a qual é assumida como constante (MALKIN, 1989).

4.1.2.3 Energia específica de retificação

Em resumo, a energia específica de retificação consiste das componentes referentes à formação do cavaco, do *plowing* e do deslizamento do grão sobre a peça, conforme a Equação 4.7 (KANNAPPAN e MALKIN, 1972 apud MALKIN, 1989):

$$u = u_{ch} + u_{pl} + u_{sl} \quad (4.7)$$

Somente **u_{ch}** (valor mínimo igual a 13,8 J/mm³) é responsável pela remoção efetiva de material. Entretanto, este valor ainda é superior ao da energia específica obtida em outros processos de usinagem de metais. Além disso, a mínima energia específica de retificação permanece constante quando se adicionam elementos de liga ou é feito um tratamento térmico no aço, gerando a mesma necessidade da mínima energia. Como exemplo, a retificação de um aço no estado recozido e de um aço ferramenta com o tratamento térmico de têmpera, ambos necessitam da mesma quantidade de energia para serem retificados (MALKIN, 1989).

A fim de se explicar este comportamento em operações de retificação, torna-se interessante comparar a magnitude da mínima energia de retificação com a energia necessária para a fusão do material que está sendo retificado.

Como apenas 75% da energia total gasta na formação do cavaco é associada à tensões de cisalhamento e os 25% restantes são gerados pelo atrito cavaco-ferramenta, a primeira

parcela gera uma energia mínima de retificação de $10,4 \text{ J/mm}^3$, a qual é idêntica à energia necessária para a fusão de uma unidade de volume de ferro. Esta igualdade pode ser atribuída às elevadas deformações envolvidas e as condições adiabáticas de formação do cavaco.

O elevado ângulo de incidência negativo dos gumes cortantes (-60°) é responsável por grandes deformações na região de corte. Estas deformações são obtidas a altas velocidades, considerando esta deformação plástica praticamente adiabática, esta energia gasta na deformação não deve exceder a energia necessária para a fusão do material. Isto é demonstrado na Figura 4.6, por uma curva hipotética tensão *versus* deformação, para um cisalhamento adiabático (MALKIN, 1989).




Figura 4.6 – Curva hipotética do comportamento tensão-deformação para um cisalhamento adiabático até a fusão do material (MALKIN, 1989 - Adaptada).

A área abaixo da curva é o trabalho plástico por unidade de volume, o qual é totalmente transformado em calor. A deformação inicial é acompanhada de um acréscimo na tensão de cisalhamento até atingir um valor máximo, decrescendo posteriormente a uma taxa constante e apresentando uma resistência à deformação plástica nula (MALKIN, 1989).

A partir deste ponto é verificado o ponto de fusão do material. Além disso, a área total abaixo da curva tensão-deformação é igual à energia por unidade de volume necessária para a fusão do material. Isto não implica na fusão do material, mas que a energia de cisalhamento gasta na formação do cavaco se aproxima da energia necessária para a fusão do material. Somente os cavacos que aparentemente entram em ignição, em contato com o ar, após a retificação mostram algum sinal de terem atingido o seu ponto de fusão (fenômeno da centelha durante a retificação) (MALKIN, 1989).

4.2 A FERRAMENTA DE CORTE

O rebolo original foi feito de argila e pó abrasivo, torneado e aquecido por *Frank B. Norton* no final de 1800. O rebolo é uma pedra artificial moldada denominada vulgarmente esmeril. É uma ferramenta de corte múltiplo, formado por uma aglomeração de cristais duríssimos que cortam o metal, raspando-o com suas pontas agudas. São constituídos de abrasivos e aglomerantes.

Segundo STEMMER (1992), na usinagem com gumes de geometria de corte não definida, a remoção do material é feita com ferramentas constituídas de grãos abrasivos de materiais duros que podem atuar livres ou unidos por um ligante. São necessárias cinco características para que se defina o tipo de rebolo:

- ❖ Tipo de abrasivo;
- ❖ Ligante;
- ❖ Dureza;
- ❖ Granulometria; e
- ❖ Estrutura.

4.2.1 Abrasivos

Os abrasivos são os agentes de corte da retificação. O elemento abrasivo é um cristal natural ou artificial em forma de pontas agudas. Os abrasivos usados na retificação podem ser subdivididos em 3 grupos (MALKIN, 1989):

- ❖ Abrasivos naturais;
- ❖ Abrasivos convencionais: óxido de alumínio, alumina com zircônio e carbureto de silício; e
- ❖ Superabrasivos (diamante e nitreto cúbico de boro ou CBN).

As características dos abrasivos que determinam sua eficiência na remoção de material são: dureza do cristal, estrutura do cristal, forma do grão, a friabilidade ou durabilidade do grão, a química do abrasivo, e se foi tratado ou revestido (MALKIN, 1989). Na Tabela 4.1, encontram-se as propriedades de alguns abrasivos.

Tabela 4.1 – Propriedades de alguns materiais abrasivos (MALKIN, 1989).

	Material			
	Óxido de Alumínio (Al ₂ O ₃)	Carbeto de Silício (SiC)	Nitreto Cúbico de Boro (CBN)	Diamante
Estrutura Cristalina	Hexagonal	Hexagonal	Cúbica	Cúbica
Densidade (g/mm³)	3,98	3,22	3,48	3,52
Ponto de fusão (°C)	~ 2.040	~ 2.830	~ 3.700	~ 3.700
Dureza Knoop (kg/mm²)	2.100	2.400	4.700	8.000

Segundo KING e HAHN (1986), a dureza do grão é um fator importante na habilidade do rebolo remover material. O diamante é o abrasivo mais duro disponível, e sua dureza o torna extremamente eficiente em algumas operações de retificação. Outras características do diamante, como suas propriedades químicas, o tornam ineficiente em outras operações. De qualquer forma um abrasivo que é significativamente mais duro que o material a ser retificado tenderá a remover mais material antes de se desgastar.

A estrutura do cristal de um grão abrasivo afeta o modo do desgaste do grão. O grão abrasivo monocristalino tende a se desgastar mais consistentemente que uma partícula abrasiva que pode ter vários cristais fundidos juntos. Grãos abrasivos apresentam enormes variações em sua microestrutura (KING e HAHN, 1986).

A dureza do abrasivo, estrutura do cristal e a forma do grão contribuem inteiramente para a relativa friabilidade ou durabilidade do abrasivo. Um grão friável é definido como um grão que fratura e expõe novos pontos agudos dentro do mesmo grão. Um grão durável pode resistir a altas forças na operação de retificação sem um desgaste muito alto. Estes dois termos (friabilidade e durabilidade) não são exatamente opostos, a medida que alguns grãos sofrem microfraturas que expõem novos pontos agudos de corte (MALKIN, 1989).

A química do abrasivo afeta a capacidade de corte do grão. Em alguns rebolos (especialmente vitrificados), uma ligação química ocorre entre o abrasivo e o ligante. A química do abrasivo pode também afetar sua capacidade de retificar materiais com os quais pode interagir em uma região de alta temperatura e alta pressão. A tendência de o diamante oxidar em altas temperaturas, por exemplo, tanto quanto sua tendência de baixa resistência ao

impacto, impede seu uso para operações de altas temperaturas e altas forças (MALKIN, 1989).

4.2.1.1 Superabrasivo de CBN

Os superabrasivos são: diamante e CBN (*Cubic Boron Nitride*). O diamante está disponível como abrasivo natural e artificial. O alto custo e disponibilidade limitada do diamante natural têm estimulado a sua troca pelo artificial ou sintético. São empregados para retificar metal duro (widia), cerâmicas, vidros e outros materiais frágeis. Há muitas formas e purezas de diamantes disponíveis. Já o CBN, que é um abrasivo artificial, é usado para retificar materiais ferrosos, particularmente aços endurecidos e/ou ligados (MALKIN, 1989).

O termo “superabrasivos” é utilizado para diferenciar os abrasivos de diamante e CBN (nitreto cúbico de boro) dos “convencionais” carbeto de silício (SiC) e óxido de alumínio (Al₂O₃). A principal propriedade de um abrasivo que diferencia o superabrasivo de um abrasivo convencional é sua dureza. Outras propriedades importantes são: resistência ao impacto, afinidade química e estabilidade térmica.

O CBN é feito de boro e nitrogênio, que previne o problema de afinidade do carbono na retificação de materiais ferrosos. É o segundo material mais duro conhecido, não é encontrado na natureza, sendo 2 a 3 vezes mais duro que o abrasivo de óxido de alumínio. Devido a sua inércia química, é o superabrasivo utilizado na retificação de ligas ferrosas e de níquel e cobalto. Este superabrasivo é sintetizado a alta temperatura e pressão no mesmo processo usado para fazer diamantes sintéticos.

O nitreto cúbico de boro foi sintetizado pela primeira vez em 1958, mas não foi comercializado até 1969. Foi rapidamente adotado para afiação de ferramentas de corte de aço de alta velocidade, mas o começo de sua utilização no processo de retificação levou mais tempo.

Contudo, o uso do CBN na retificação desenvolveu-se rapidamente no Japão, Europa e Estados Unidos. O consumo de rebolos e pedras de afiar de CBN usados para retificação de produção já excede significativamente o gasto usado para manutenção de ferramenta (KING e HAHN, 1986).

Atualmente, existe uma grande utilização de rebolos de CBN no mercado. Abrangendo indústrias tais como: as automobilísticas; aeroespaciais; de componentes de motores; etc. Embora o rebolo de CBN tenha um elevado custo inicial, quando comparado com rebolos de óxido de alumínio, sua aplicação é compensada desde que o custo operacional total seja reduzido (OLIVEIRA et al., 2002).

Diversos estudos já mostraram a maior vida do rebolo de CBN em relação à rebolos convencionais, deste modo, sabe-se que a utilização do mesmo gera uma maior economia global no processo (HITCHINER, 1999).

Os danos térmicos gerados na retificação com rebolos superabrasivos de CBN são, geralmente, inferiores aos que ocorrem na retificação com rebolos convencionais (MALKIN, 1985). Utilizando-se rebolos de CBN, a queima da peça raramente ocorre e as tensões residuais são, predominantemente de compressão (TÖNSHOFF e GRABNER, 1984; VANSEVENAT, 1989). Isto indica que menores temperaturas de retificação são geradas na região de corte. Estas são parcialmente atribuídas à menor energia gasta para a retificação com rebolos de CBN, devido à maior dureza de seus grãos (KOHLI et al., 1995).

Isto mantém a capacidade de corte do rebolo durante tempos maiores, diminuindo o desgaste do mesmo. Todavia, tem-se atribuído as menores temperaturas geradas na retificação com rebolos de CBN a maior condutividade térmica de seus grãos abrasivos, quando comparadas com os de óxido de alumínio. Assim uma fração muito maior do calor gerado é transportada para fora da zona de retificação pela ferramenta abrasiva, ao invés do mesmo fluir pela peça (LAVINE et al., 1989).

Deste modo, a menor partição de energia permite uma diminuição das temperaturas na região de corte e uma menor tendência de indução de danos térmicos à peça. Além disso, a utilização do rebolo de CBN também gera, na maioria dos casos, tensões residuais de compressão na superfície e subsuperfície da peça retificada, aumentando assim, a sua resistência à fadiga e conseqüentemente a vida útil do componente (OLIVEIRA et al., 2002).

4.2.2 Ligante

O ligante ou aglutinante tem a função de manter o grão preso, até que este esteja cego o suficiente e perca a capacidade de corte em decorrência do processo de usinagem. O ligante deve satisfazer as seguintes exigências:

- ❖ O material ligante deve ser suficientemente resistente;
- ❖ O ligante deve formar pontes entre grãos com seções transversais suficientemente grandes para suportar os esforços de corte; e
- ❖ Entre o grão abrasivo e o ligante deve existir uma energia de ligação suficientemente elevada para garantir a fixação do grão.

Os ligantes são classificados em vitrificados, resinóides, galvânica, entre outro.

4.2.3 Dureza

Denomina-se dureza a resistência oposta ao arrancamento dos grãos, ou seja, uma capacidade de reter os grãos. Esta capacidade depende do tipo de ligante, do tamanho do grão e dos vazios e da espessura das pontes de ligantes. Um rebolo macio solta facilmente os grãos e gasta mais rapidamente, logo, um rebolo duro retém fortemente os grãos abrasivos.

A dureza ideal a ser utilizada é aquela que os grãos gastos e arredondados são arrancados por si só, de modo que o rebolo se afie automaticamente, com mínima necessidade da operação de dressagem.

4.2.4 Granulometria

As dimensões dos grãos e sua uniformidade são características importantes nos processos de usinagem com abrasivos. O tamanho do grão é especificado em *mesh*.

Os grãos mais grossos são utilizados em rebolos para operações de corte e limpeza, enquanto os mais finos, até 1.200 *mesh*, são utilizados para polimento e lapidação.

4.2.5 Estrutura

A estrutura do rebolo não tem relação direta com a densidade ou com a porosidade, mas com o espaçamento entre os grãos abrasivos. A estrutura aberta é indicada pelos números 0, 1, 2, 3; a média pelos números 4, 5, 6 e de 7 a 12 a estrutura é fechada. Uma estrutura fechada determina um aumento no número de arestas cortantes na periferia do rebolo. Rebolos com estrutura aberta oferecem mais espaços para alojamentos do cavaco reduzindo a tendência ao entupimento de porosidades.

Na seleção do tipo de estrutura utilizada na operação, devem ser analisados três fatores: o material a ser usinado, o acabamento desejado e o tipo de trabalho.

4.3 O PERFILAMENTO E A AFIAÇÃO DA FERRAMENTA

Após a fabricação e o uso prolongado, as ferramentas para retificação podem apresentar gumes cegos, variação na forma e poros impregnados de cavaco, de modo que a remoção de material fica prejudicada. Portanto, deve-se fazer do processo a operação de dressagem ou avivamento. A operação conjunta de perfilamento e afiação de rebolos convencionais na retificação é denominada operação de dressagem. Já a operação de avivamento é realizada para rebolos superabrasivos (OLIVEIRA et al., 1992).

Para tal operação, são utilizados diversos tipos de ferramentas denominadas dressadores que incluem: cortadores metálicos (rosetas), bastões retificadores, rodas retificadoras, pontas

simples de diamante, dressadores de diamantes múltiplos e em matriz, roletes estacionários e giratórios de diamante e roletes de esmagamento. Cada tipo apresenta vantagens específicas.

As principais finalidades da operação de dressagem são:

- ❖ Obtenção de concentricidade da face de trabalho com o eixo de rotação;
- ❖ Perfilamento da face de trabalho para uma operação de forma; e
- ❖ Arrancamento dos grãos abrasivos gastos para melhorar a agressividade da face de trabalho.

4.3.1 Ferramentas de Dressagem

Segundo KÖNIG (1980), as ferramentas de dressagem se distinguem de acordo com o princípio cinemático de ação: ferramentas estáticas e ferramentas rotativas.

Para as ferramentas estáticas, ao contrário das rotativas, não existe um movimento de rotação, apenas translação.

As ferramentas fixas de dressagem trabalham da mesma forma que uma ferramenta de torneamento onde o rebolo é a peça a ser torneada. Esta ferramenta é geralmente fixa à mesa de trabalho ou sobre um dispositivo especial de dressagem e é deslocada com uma velocidade de avanço constante (V_{sd}). Entre as passadas, a ferramenta avança um valor de profundidade ou penetração (a_d).

As ferramentas com contato pontual, assim como na forma de linha, também são adequadas para o perfilamento. O perfil é produzido pelo movimento da ferramenta de dressagem que é guiada por um sistema copiador. Pode-se encontrar atualmente ferramentas de dressagem comandadas numericamente.

A ferramenta rotativa trabalha da mesma forma que a estática, sendo avançada longitudinalmente ao longo do rebolo. As demais ferramentas não necessitam de um movimento de avanço, uma vez que têm uma largura de trabalho (b_d) que é maior ou igual à largura do rebolo (b_s). A velocidade de penetração (V_{fd}) pode ser realizada pelo movimento intermitente nas ferramentas em bloco ou na forma de um movimento contínuo de dressagem por rolo. Em ambos os casos a ferramenta executa movimento de penetração radial em relação ao rebolo. O perfil da ferramenta de dressagem é reproduzido de forma recíproca na superfície do rebolo.

Para que durante a dressagem seja possível a remoção de material do rebolo, as ferramentas de dressagem devem ser mais duras que o material do rebolo. Em decorrência disto, para a dressagem de rebolos convencionais são empregadas ferramentas de diamante. Além da dressagem do rebolo por corte, também é usual empregar-se uma sobrecarga de

retificação sobre o rebolo, produzindo um efeito de remoção de material de sua superfície. Na retificação de materiais extremamente duros e sob condições extremas de usinagem, são produzidas grandes forças de cortes nos contornos dos grãos abrasivos. Estas forças fazem com que os grãos abrasivos cegos lasquem ou sejam expulsos do ligante.

4.4 A LUBRI-REFRIGERAÇÃO NO PROCESSO DE RETIFICAÇÃO

4.4.1 *Fluidos de Corte*

Segundo RUNGE e DUARTE (1989), alguns conceitos utilizados para a indicação dos tipos de fluidos de corte, assim como sua constituição, são mencionados a seguir:

- ❖ **Fluido básico:** Refere-se a todos os fluidos de corte, como óleos minerais, água e outros utilizados isoladamente ou com aditivos em operações de corte ou similar;
- ❖ **Fluido de corte:** Tipo genérico de fluido para usinagem de metais ou outros materiais;
- ❖ **Óleo integral:** Fluido de corte à base de óleos minerais, utilizado na forma como é fornecido, sem mistura com água e denominados também de óleo puro;
- ❖ **Óleo solúvel:** Fluido de corte à base de óleos minerais, podendo conter qualquer conteúdo de óleo mineral em qualquer teor, podendo também ser misturado com água formando as emulsões;
- ❖ **Óleo solúvel concentrado:** Compõe o óleo solúvel propriamente dito em estado de fornecimento, antes de ser misturado na água;
- ❖ **Fluido sintético:** Fluido de corte que não possui óleo mineral em sua constituição, sendo o mesmo utilizado misturado em água formando uma solução; e
- ❖ **Fluido Semi-sintético:** O fluido semi-sintético apresenta uma pequena porção de óleo mineral em sua constituição. Tal fluido é misturado em água, formando uma emulsão muito fina, parecida com as soluções. Outro termo que pode ser direcionado à estes tipos de fluidos é fluido de corte com baixo teor de óleo mineral.

De acordo com MONICI (2002), os fluidos de corte podem ser vistos como parte integrante do processo de fabricação de componentes industriais, por meio da remoção de cavacos, num sistema que envolve a máquina retificadora, o fluido de corte, as peças em produção e a ferramenta. Com a grande competitividade existente no mercado, o sucesso de

determinado produto é atingido pela excelente correlação entre os fatores citados. Assim a escolha adequada de fluidos de corte com relação aos diversos fabricantes e tipos de fluidos existentes no mercado exige extrema atenção. O fluido de corte influi diretamente sobre alguns fatores como:

- ❖ a qualidade superficial das peças;
- ❖ produtividade;
- ❖ custo operacional; e
- ❖ meio ambiente.

4.4.1.1 Fluidos de corte solúveis em água

Os fluidos de corte solúveis em água transformam-se em misturas, quando seu concentrado é diluído em água. Estas misturas variam entre emulsões e soluções dependendo da constituição básica do concentrado (óleo mineral ou sais orgânicos e inorgânicos, respectivamente), da presença e da quantidade de emulgadores no mesmo. Dependendo da taxa de diluição e da constituição do concentrado do fluido solúvel, o fluido de corte pode apresentar uma refrigeração eficiente aliado a um moderado poder lubrificante (SILVA, 2000).

Nas emulsões o óleo mineral está disperso na água em forma de gotículas, devido à presença de emulgadores, os quais “quebram” o óleo mineral em minúsculas partículas (gotículas), mantendo-as dispersas e evitando a sua coalescência (união das gotículas de óleo e separação da fase oleosa da aquosa). Apresentam menor poder lubrificante e maior poder refrigerante que o óleo de corte. Todavia necessitam de cuidados especiais quanto à qualidade da água utilizada, ao controle de microrganismos (bactérias e fungos), ao pH e à concentração da emulsão (SILVA, 2000).

Os fluidos sintéticos são soluções químicas constituídas de materiais (sais) orgânicos e inorgânicos dissolvidos em água, não contendo óleo mineral. Em geral, permitem rápida dissipação de calor, bom controle dimensional, excelentes poder detergente e visibilidade da região de corte, facilidade no preparo da solução, elevada resistência à oxidação do fluido e à ferrugem. Sua utilização vem crescendo em função do custo elevado dos fluidos de corte integrais, devido às dificuldades de descarte e das restrições atuais quanto a sua utilização. O baixo poder lubrificante, a formação de compostos insolúveis e de espuma para determinadas operações de usinagem podem ser caracterizadas como desvantagens na utilização deste tipo de fluido (SILVA, 2000).

4.4.2 Funções do Fluido de Corte

Segundo RUNGE e DUARTE (1989), as principais funções dos fluidos de corte são:

- ❖ refrigerar;
- ❖ lubrificar;
- ❖ melhorar o acabamento superficial;
- ❖ reduzir o desgaste das ferramentas;
- ❖ remover os cavacos da área de corte;
- ❖ proteger contra a corrosão (máquina, ferramenta, peça e os cavacos); e
- ❖ lubrificar guias e barramentos.

A refrigeração do processo, é uma das funções primárias dos fluidos de corte. Os mesmos atuam visando a remoção de calor da área de contato entre a ferramenta e a peça, aumentando a vida útil da mesma e garantindo maior precisão dimensional destas por meio da redução das distorções térmicas ocorridas. As pressões geradas, durante a usinagem são em torno de 1,4 GPa, sendo que aproximadamente 75% do calor gerado é devido à deformação do material e outros 25% do calor gerado é resultado do atrito da ferramenta com o cavaco.

Em situações nas quais o calor gerado não é retirado de maneira efetiva, excessivas dilatações térmicas ocorrerão na peça, resultando também em elevado desgaste da ferramenta, gerando repetitivas operações de manutenção (RUNGE e DUARTE, 1989).

4.4.3 Otimização da Aplicação de Fluidos de Corte

A importância da aplicação do fluido de corte é freqüentemente observada de maneira superficial. Se o mesmo não é aplicado de forma correta, não pode lubrificar, refrigerar e limpar o material usinado. Há poucos exemplos na literatura que descrevem a aplicação do fluido com detalhes específicos. Isto porque poucos estudos foram desenvolvidos com relação à métodos práticos para se medir o efeito das variáveis envolvidas no processo, quanto ao volume de fluido de corte que pode ser utilizado. Recentemente tem sido polêmico o debate a respeito da quantidade de fluido de corte que deve ser aplicada. Alguns temas envolvidos são: a velocidade do fluido de corte, velocidade da ferramenta, ângulo do bocal, melhor projeto do bocal etc. (MONICI, 2002).

Segundo WEBSTER (1995), o desempenho dos fluidos de corte pode ser melhorado com o aperfeiçoamento de seu sistema de aplicação. Isto significa que a bomba, o formato do bico (ou bocal) e as tubulações devem ser aprimorados para que sejam obtidas peças retificadas de melhor qualidade (WEBSTER, 1995 e 1999).

O bico deve ser projetado para garantir a coerência do jato de fluido de corte. WEBSTER (1995) desenvolveu um novo bocal, de formato arredondado, baseando-se no bico desenvolvido por ROUSE et al. (1952), para mangueiras de combate à incêndios. Este bocal é apresentado na Figura 4.7.




Figura 4.7 – Bocal de formato arredondado (WEBSTER, 1995).

Onde: C_r é a razão de contração, D é o diâmetro da mangueira de alimentação de fluido de corte e D_n é o diâmetro de saída do bocal de fluido de corte.

Os bocais tradicionais de fluido de corte têm uma ou duas paredes internas convexas, conforme apresentado na Figura 4.8, que ocasionam a separação do fluxo de fluido (WEBSTER, 1995).




Figura 4.8 – Bocal tradicional (WEBSTER, 1995).

O fluxo de fluido separado é turbulento e apresenta uma queda de pressão na saída, a qual afetará, significativamente, a coerência do jato. De forma contrária, o bocal de formato arredondado tem paredes internas côncavas, o que garante uma maior coerência do jato (WEBSTER, 1995).

No projeto do bico de fluido de corte deve-se considerar (WEBSTER, 1995):

- ❖ a geometria de entrada e de saída do bico;
- ❖ um acabamento superficial adequado (redução das perdas por atrito);
- ❖ a eliminação de cantos vivos e uma razão de contração elevada;
- ❖ o posicionamento do bico;
- ❖ a vazão mínima requerida a fim de se evitar a queima superficial da peça;
- ❖ a capacidade nominal da bomba de fluido de corte;
- ❖ a utilização de tubulações flexíveis e de diâmetro adequado (redução da perda de carga); e
- ❖ as quedas de pressão, resultado de curvas acentuadas na linha de alimentação.

A angulação do bocal tem pouca influência no desempenho do fluido de corte, desde que seu fluxo seja direcionado adequadamente na região de corte. Todavia, o aumento da distância entre o bico e a região de corte reduz a eficiência de aplicação, principalmente quando da utilização de bicos com baixa coerência do jato. Conseqüentemente, o bocal de fluido de corte deve ser posicionado o mais próximo possível da peça a ser retificada (WEBSTER, 1995).

A velocidade do jato de fluido de corte (V_j) deve ser igual à velocidade periférica do rebolo, permitindo-se suplantá-la a barreira de ar criada pela rotação do mesmo. WEBSTER (1995 e 1999) afirma que a relação unitária (1:1) entre a velocidade do jato e a velocidade de corte (V_s) deve ser utilizada na maioria das aplicações, exceto onde a potência requerida e o custo da bomba de fluido de corte forem excessivos.

WEBSTER (1995) investigou a relação entre velocidade de saída do jato e a velocidade de corte por meio de testes laboratoriais, nas quais o fluxo de calor foi medido para três velocidades de corte, sendo que as velocidades de saída do jato utilizadas variaram entre valores inferiores e superiores à velocidade de corte. Os resultados indicam que o fluxo de calor mantém-se constante a partir do valor V_j/V_s igual a um (relação unitária).

Medições da pressão hidrodinâmica podem ser utilizadas para otimizar a aplicação de fluido de corte, em termos de direcionamento do bico, velocidade e vazão. Adicionalmente, a ocorrência de pressões positivas na região de corte indica que o efeito de evaporação do filme

de fluido de corte está ocorrendo e que, conseqüentemente, a taxa de remoção de material deve ser diminuída (WEBSTER, 1995).

A melhoria do efeito de lubri-refrigeração na zona de retificação, resultado da aplicação de fluido de corte à alta velocidade, é responsável pela otimização do processo de retificação, pela redução do empastamento do rebolo e de uma limpeza mais efetiva do mesmo (KOVACECIC e MOHAN, 1995).

Além disso, as altas velocidades de aplicação permitem uma reafiação do rebolo, pela remoção de grãos já desgastados e mal ancorados de sua superfície. As elevadas vazões utilizadas melhoram a remoção de calor por convecção, impedindo a completa evaporação do filme de fluido de corte da zona de retificação. O desempenho do fluido é melhorado com o aumento de sua velocidade de aplicação. Como resultado tem-se a redução das forças de corte, desgaste do rebolo e incidência de queima, permitindo portanto uma melhoria geral do processo de retificação (KOVACECIC e MOHAN, 1995).

Segundo CAMPBELL (1995), alguns dos fatores que afetam a eficiência da lubri-refrigeração são:

- ❖ Posicionamento do bocal;
- ❖ Velocidade do fluido;
- ❖ Quebra da barreira aerodinâmica;
- ❖ Desenho do bocal;
- ❖ Tamanho do grão abrasivo;
- ❖ Tipo de fluido de corte; e
- ❖ Ângulo de abertura do bocal.

4.4.3.1 A quebra da barreira aerodinâmica

Uma das metodologias propostas para a otimização do processo de lubri-refrigeração, é a quebra da barreira aerodinâmica gerada pela rotação do rebolo no processo. Deste modo, devido à velocidade periférica da ferramenta, ocorre o aparecimento de uma camada de ar ao redor da superfície do rebolo e o fluido de corte muitas vezes não penetra na região de corte.

Uma metodologia desenvolvida para evitar este fenômeno, foi a utilização de um dispositivo chamado defletor que anula o efeito gerado pelo rebolo. O mesmo procura captar a pressão exercida pelo ar na região de contato entre rebolo e peça. Com o aumento da velocidade do rebolo, o efeito da barreira de ar criada pelo mesmo torna-se mais pronunciada (CAMPBELL, 1995).

Um importante resultado obtido, conforme Figura 4.9, mostra que o aumento da velocidade periférica do rebolo (ou rotação), acima de uma velocidade crítica (N_s), prejudica a penetração do fluido de corte na região de contato peça-ferramenta. Assim pode-se notar que a utilização do defletor acarreta em uma velocidade crítica maior que o caso sem dispositivo. A velocidade crítica está intimamente ligada com o tipo de ferramenta utilizada, bocal utilizado e velocidade do fluido de corte.




Figura 4.9 – Velocidade crítica do rebolo com e sem dispositivo (*air scrapper*) de quebra de barreira aerodinâmica (CAMPBELL, 1995 - Adaptada).

A velocidade máxima, ou crítica, conseguida com o dispositivo (*air scrapper*) é 22% maior do que a conseguida sem o mesmo. Para estas condições particulares, a velocidade do rebolo acima da rotação crítica, ocasiona a não penetração do fluido de corte na região de corte e portanto aumenta a temperatura (CAMPBELL, 1995). A Figura 4.10 ilustra o efeito da presença do dispositivo no processo.




Figura 4.10 – Efeito do dispositivo (*air scrapper*) na medida da pressão hidrodinâmica e fluxo de fluido de corte (CAMPBELL, 1995 - Adaptada).

De acordo com a Figura 4.10, o melhor desempenho foi alcançado com a presença do dispositivo, pois a pressão é maior quando comparada com a segunda situação. Tal ocorrência indica a maior penetração do fluido na região de contato entre a ferramenta e a peça, possibilitando que o mesmo desempenhe suas funções de maneira satisfatória. O aumento da porcentagem de fluido de corte presente na região de corte foi calculado, resultando em um aumento de 16% quando comparado à situação original (com barreira aerodinâmica) (CAMPBELL, 1995).

Outras técnicas utilizadas para melhorar o desempenho do processo compreendem de dispositivos capazes de determinar a eficiência do fornecimento de lubri-refrigerante na região de corte. Um tipo de dispositivo encontrado, trata-se de um pedaço plano de 0,062 pol. (1,57 mm) de aço parafusado próximo ao rebolo ao longo da largura do mesmo contra a corrente ou ligeiramente acima do bocal do fluido. Tal dispositivo colocado contra a superfície de trabalho do rebolo, usando-se um rebolo de CBN de uma polegada (25,4 mm) de largura foi testado com um óleo não diluído (WEBSTER, 1995).

Além deste aparato, há um segundo desenho de dispositivo testado com o mesmo objetivo, feito com a mesma espessura, parafusado na mesma posição acima do bocal do fluido, porém envolvendo o rebolo de ambos os lados. Isto foi conseguido pela retificação do

pedaço de metal de aproximadamente $\frac{3}{4}$ de polegada (19 mm) com os mesmos 30 μm do rebolo de CBN utilizado no teste anterior. A diferença obtida neste segundo tipo de dispositivo foi um relativo aumento de 5% na rotação crítica do rebolo quando comparado com o primeiro, que não envolveu os lados do rebolo. Assim, pode-se concluir que o vencimento da barreira aerodinâmica pode proporcionar excelentes resultados no que tange à qualidade da peça retificada. Neste projeto tal ocorrência é evidenciada pelo novo projeto e formato do bocal de aplicação de fluido de corte, sendo o mesmo capaz de vencer a barreira aerodinâmica pela relação unitária de velocidades entre ferramenta/rebolo (WEBSTER, 1995).

Tendo conhecimento destes novos conceitos, tem-se que a eficiência da aplicação do fluido de corte na interface peça-rebolo pode ser otimizada, e o surgimento de uma tendência da diminuição da temperatura na peça tornou-se real. O processo se torna mais estável, sendo que as variações do sistema como o aumento na temperatura do fluido e a expansão térmica da peça terão menores efeitos, além de outras variáveis de saída do processo intimamente ligadas à variação térmica, como a tensão residual.

4.5 A REDE NEURAL ARTIFICIAL - RNA

4.5.1 Introdução

As redes neurais foram desenvolvidas, originalmente, na década de 40, pelo neurofisiologista *Warren McCulloch*, do MIT, e pelo matemático *Walter Pitts*, da Universidade de Illinois, os quais fizeram uma analogia entre células nervosas vivas e o processo eletrônico. O trabalho consistia num modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio biológico (TAFNER, 2004a).

Desde então, mais enfaticamente a partir da década de 80, 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, 2004b).

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. Portanto, as redes neurais artificiais (RNA's) apresentam um modelo matemático inspirado na

estrutura neural de organismos inteligentes e que 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. Estes têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio (CARVALHO, 2004).

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 pelas sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre os mesmos (CARVALHO, 2004).

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”. Este 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 (CARVALHO, 2004).

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, 2004b). A representação de um neurônio artificial e de um neurônio biológico pode ser observada na Figura 4.11.




Figura 4.11 – Neurônio biológico (acima) e neurônio artificial (abaixo). Onde: $\mathbf{x}$ é o vetor entrada; $\mathbf{w}$ o vetor peso, θ_k o *bias* e y_k a saída do neurônio k (HAYKIN, 2001 - Adaptada).

Combinando diversos neurônios artificiais pode-se 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 (TAFNER, 2004b).

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.) os quais se deseja que a rede reconheça quando em operação (TAFNER, 2004b).

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 este estímulo for apresentado a esta rede neural, aquele neurônio que foi treinado para representá-lo, automaticamente irá ser disparado, informando desta forma, qual o estímulo que foi apresentado para a rede neural (TAFNER, 2004b).

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 (TAFNER, 2004b).

A propriedade mais importante das redes neurais é a habilidade de aprender seu ambiente e com isto 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, 2004).

Inúmeras aplicações surgiram desde a década de 80, 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;
- ❖ 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.

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

Em essência, um conjunto de entradas (vetor $\mathbf{x}$) é aplicado a um neurônio artificial, cada uma representando uma saída de outro neurônio. 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 4.8 e 4.9 (HAYKIN, 2001):

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (4.8)$$

$$y_k = \varphi(u_k + \theta_k) = \varphi(v_k) \quad (4.9)$$

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

Tabela 4.2 – Tipos de funções de ativação e suas representações gráficas (BAUCHSPIESS, 2004).

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

Os tipos mais utilizados da função de ativação (Tabela 4.2) 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 $(-\infty \text{ e } +\infty)$ 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 sigmoidal, 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 este, 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 (TATIBANA e KAETSU, 2004).

4.5.3 Arquitetura da RNA

A definição da arquitetura de uma rede neural é um parâmetro importante na sua concepção, uma vez que esta restringe os tipos de problemas que podem ser tratados pela rede (NAVAUX e BOSCHETTI, 2004).

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, inclui-se 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.

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. 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. Esta 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 apresentarem 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.

4.5.4 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:

- ❖ **Reconhecimento de padrões:** A tarefa a ser desempenhada é a de atribuir um padrão de entrada a uma das várias classes pré-definidas. Esta 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 que as redes neurais processam dados com base em transformações, a computação tradicional faz uso de algoritmos que representam regras. A experiência tem mostrado que estas duas abordagens de processamento da informação são complementares do ponto de vista operacional, mas incompatíveis em termos conceituais (TANURI, 2004).

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, 2004).

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 et al., 1999). Assim, esta técnica pode também vir a ser utilizada para a predição de outras características do processo.

4.5.5 Principais Características das Redes Neurais Artificiais

As principais características das RNA's podem ser resumidas como segue:

- ❖ **Aprendizado por meio 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 minimizado;
- ❖ **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 sinápsis 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 à 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.

4.5.6 Treinamentos de Redes Neurais Artificiais

O processo de ajuste de uma rede neural artificial para determinado problema, consiste em um processo de aprendizado. Neste 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.

A maneira como uma rede é treinada constitui um padrão classificatório para as mesmas. Como já dito anteriormente, o treinamento das redes pode ser classificado em dois grupos:

- ❖ **Supervisionado:** A rede é treinada para fornecer a saída desejada em relação a um estímulo de entrada específico. Exemplos de redes que utilizam este tipo de treinamento são as que usam a regra Delta. Como exemplo, tem-se as redes *perceptrons*; e
- ❖ **Não Supervisionado:** Não há uma 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*.

4.5.7 Tipos de RNA's

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

4.5.7.1 Perceptron

O *perceptron* é uma forma simples de uma rede neural utilizada para a classificação de padrões. São constituídas 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 isto que as funções de ativação do *perceptron* podem ser a função degrau para casos onde a resposta deva ser 0 ou +1, ou então a função degrau simétrico para situações onde a saída deve assumir os valores +1 e -1.

Tipicamente as entradas e os pesos das conexões, neste 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 esta 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 esta 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*. Este 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:

$$\mathbf{w}_i^{k+1} = \mathbf{w}_i^k + \Delta \mathbf{w}_i \quad (4.10)$$

$$\Delta \mathbf{w}_i = \eta (\mathbf{y}_i^d - \mathbf{y}^d) \mathbf{x}_{ij}^d \quad (4.11)$$

Onde:

d é um índice que significa desejado;

w é a matriz de pesos;

$\mathbf{x}$ e $\mathbf{y}$ 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.

Esta 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:

$$\mathbf{y} = \text{sgn}\left(\sum_{i=1}^{n+1} \mathbf{w}_i \mathbf{x}_i\right) = \text{sgn}(\mathbf{w}^T \mathbf{x}) \quad (4.12)$$

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* atinge seu mínimo. O *Perceptron*, depois de treinado, separa linearmente duas coleções através de um hiperplano contido no hiperespaço destes conjuntos. Este hiperplano é chamado de superfície de decisão. A aprendizagem, do ponto de vista geométrico, pode então ser resumida a um processo de determinação deste hiperplano no espaço multidimensional das entradas.

O que *Minsky* e *Papert* 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 4.12).




Figura 4.12 – Diferenças entre um problema linearmente separável e outro não-linearmente separável (OLIVEIRA, 2004).

Note 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 deste tipo de problema foi encontrada em arquiteturas de *perceptrons* multicamadas (MLP) e da generalização da *Regra Delta*, os quais serão vistos no item 4.5.7.2.

4.5.7.2 Perceptron multicamadas e backpropagation

Uma importante classe de redes neurais são as redes multicamadas, mais comumente chamadas *perceptron* multicamadas.

Estas 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 $\mathbf{x}$ e a saída desejada (vetor $\mathbf{y}$) (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. Já que se este número é pequeno, a rede pode não aprender. E se for grande demais, há o risco de uma especialização excessiva e a perda da capacidade de generalização (AZEVEDO et al., 2000).

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 destes neurônios recebe uma entrada. A saída dos neurônios na camada de saída corresponde às saídas da rede.

Este tipo de rede pode ser utilizado para aproximação de funções, reconhecimento de padrões, controle e predição de parâmetros de processos.

Uma rede de *perceptrons* multicamadas pode ser esquematizada como na Figura 4.13.




Figura 4.13 – Esquematização de uma rede *perceptron* multicamadas.

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 4.14 ilustra esta afirmação.




Figura 4.14 – Fase *forward* e *backward* do treinamento de retropropagação (THOMÉ e OLIVEIRA, 2004).

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 comparada 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 este 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.

4.5.8 Taxa de Aprendizado e Momentum

Apesar de já terem sido citadas anteriormente, 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. Este tipo de problema pode ser minimizado com o auxílio do *Momentum* 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.

4.5.9 Validação Cruzada (Cross-Validation)

A validação cruzada é uma metodologia utilizada para selecionar uma arquitetura de *perceptrons* multicamadas entre vários modelos candidatos. Nesta técnica, os seguintes passos devem ser seguidos:

- ❖ 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.

4.5.10 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 e RAJAGOPALAN, 1996).

A grande oferta de *softwares* e ferramentas de modelamento e implementação de RNA's, têm 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, esta 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 estes 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 deste 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 este 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 estes 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 e SONG (2001) utilizou uma rede neural treinada pelo algoritmo *backpropagation* para a predição de problemas freqüentemente 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 et al. (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 et al. (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. Este fenômeno é decorrente de mudanças nas propriedades metalúrgicas dos materiais devido a uma usinagem severa ou até mesmo um método de fabricação inadequado. 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 com os treinamentos, a RNA obteve uma excelente performance neste trabalho.

OLIVEIRA et al. (1996) apresentaram, 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 aos extremos os tempos e custos de usinagens. Para isto utilizam-se de inúmeros artifícios 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. Estes, 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 (OLIVEIRA et al., 1996).

5 MATERIAIS E MÉTODOS

Este capítulo tem o objetivo de descrever todos os equipamentos, materiais e métodos utilizados nesta pesquisa científica. De modo a registrar os procedimentos pré e pós-ensaios, promovendo assim a possibilidade de reprodução dos experimentos.

Devido à natureza multidisciplinar desta pesquisa, a experimentação pode ser dividida em duas etapas. A primeira diz respeito à parte mecânica propriamente dita, pois esta fase abrange os experimentos realizados na retificadora cilíndrica externa. Já a segunda etapa está relacionada com os procedimentos realizados no modelamento da rede neural artificial e sua implementação.

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. As demais variáveis indiretas de saída (rugosidade, circularidade e desgaste diametral do rebolo) foram medidas nos laboratórios didáticos da UNESP – Bauru. 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.

5.1 EQUIPAMENTOS UTILIZADOS

Os ensaios de usinagem foram executados em uma retificadora cilíndrica modelo RUAP 515 H, com comando numérico computadorizado CNC, fabricada pela empresa *SULMECÂNICA*, conforme a Figura 5.1.




Figura 5.1 – Retificadora cilíndrica modelo RUAP 515 H, *SULMECÂNICA*.

Os procedimentos realizados para a modelagem e execução da RNA foram desenvolvidos nas dependências do LUA, utilizando-se como ferramenta o *software* Matlab 6.5, da empresa *The MathWorks, Inc.*

5.1.1 Equipamentos do Sistema de Aquisição de Dados

A máquina foi equipada com sensores (emissão acústica e rotação) e circuitos condicionadores de sinais para a medição das variáveis de saída.

5.1.1.1 Emissão acústica

Para a medição da emissão acústica foi utilizado um sensor EA, conectado a uma unidade de tratamento de sinal, modelo DM 42, ambos fabricados pela empresa *SENSIS*. Esta unidade de tratamento de sinais filtra e amplifica o sinal e ainda é responsável pelo cálculo do valor médio quadrático – RMS (*Root Mean Square*). A Figura 5.2 mostra a unidade de tratamento de sinal.




Figura 5.2 – Fontes e unidade de tratamento de sinal de emissão acústica.

5.1.1.2 Rotação da ferramenta

Um *encoder* industrial blindado, modelo TH 10 R 30000, fabricado pela empresa *ABRAF*, foi utilizado para a medição da rotação do rebolo. Este foi acoplado ao eixo do motor de indução do cabeçote porta-rebolo com um acoplamento flexível de acordo com a Figura 5.3.




Figura 5.3 – Fixação do *encoder* no eixo do motor do cabeçote porta-rebolo.

5.1.1.3 Potência elétrica do motor

Para a medição da potência do motor, foi utilizado um equipamento desenvolvido pelo Laboratório de Aquisição e Processamento de Dados (LADAPS), sob a supervisão do Prof. Dr. Paulo Roberto de Aguiar. Este medidor de potência, ou *curvopower*, recebe os valores de tensão (V) e correntes (I_a) provenientes do motor da retificadora e libera uma tensão (V) referente à potência para uma placa de aquisição de dados. Este aparelho pode ser visualizado na Figura 5.4.



Figura 5.4 – *Curvopower* ou medidor de potência.

5.1.1.4 Condicionadores de sinais e placa (A/D)

Foi utilizado um módulo ou caixa de conexões, também desenvolvido pelo LADAPS, onde foram conectados os sinais provindos da unidade de tratamento de sinal (emissão acústica), do *encoder* (rotação) e do módulo de potência ou *curvopower* (potência elétrica).

Esta caixa de conexões faz a ligação dos sinais das variáveis medidas com a placa de aquisição de dados.

Para que o computador entenda os dados provindos do sistema, estes sinais sofrem uma conversão do modo analógico para o modo digital. Para isto foi utilizada uma placa de aquisição de dados de 12 bits, modelo PCI-6111E, do fabricante *National Instruments*. Esta placa foi instalada em um microcomputador do tipo PC *Pentium III* de 700 MHz.

A Figura 5.5 exibe a central de aquisição de dados com o microcomputador, os condicionadores de sinais e as fontes utilizadas no trabalho.




Figura 5.5 – Vista da central de aquisição de dados do LUA.

5.1.1.5 Softwares

Foi utilizado ainda o *software* LabVIEW 6.1, da *National Instruments*, para realizar a interface entre a placa de aquisição de dados e o computador, através de um VI (*Virtual Instrument*). Este programa utiliza a linguagem G, ou seja, uma linguagem gráfica para realizar a aquisição propriamente dita, assim como a exibição on-line e gravação dos valores. É importante ressaltar que cada grandeza medida (emissão acústica, rotação e potência do motor) foi destinada a um canal diferente da placa de aquisição de dados A/D. Os valores em Volts que representavam estas grandezas foram gravados em arquivos distintos pelo LabVIEW 6.1 para serem tratados posteriormente.

O software Matlab 6.5, da empresa *The MathWorks, Inc.*, foi a ferramenta utilizada para o tratamento final dos dados obtidos nos ensaios.

5.2 MATERIAIS UTILIZADOS

5.2.1 Rebolo

Nesta pesquisa foi utilizado como ferramenta de corte um rebolo superabrasivo de CBN (nitreto cúbico de boro) do tipo 14A1, de especificação SNB151Q12VR2, com ligante vitrificado, de dimensões 350 x 10 - 3 x 127, fabricado pela empresa NIKKON Ferramentas de Corte Ltda. A Figura 5.6 exibe o rebolo de CBN utilizado nos ensaios.




Figura 5.6 – Rebolo de CBN 14A1, de especificação SNB151Q12VR2.

5.2.2 Corpo de Prova

O material do corpo de prova utilizado foi o aço VC-131, temperado e revenido com dureza média de 62 HR_c. A composição química deste aço é apresentada na Tabela 5.1.

Tabela 5.1 – Composição química do aço VC-131 em % (KNIFECO, 2004).

Material	C	Cr	Mn	V	W	F _e
VC-131	2,10	11,50	0,30	0,20	0,70	Balanço

A Figura 5.7 apresenta a geometria do corpo de prova com as medidas em milímetros. Este possui a seção em forma de “H”, com duas faces para a execução dos ensaios. Foi realizado apenas um ensaio (repetibilidade) em cada face. No entanto, utilizou-se para cada

grupo de ensaios quatro faces, ou dois corpos de prova, sendo que a quarta região do segundo corpo de prova também foi retificada para que não ocorresse nenhum erro na medição de circularidade da terceira repetibilidade, já que para esta medição é necessário fixar a peça pela quarta região, como será visto adiante.




Figura 5.7 – Dimensões do corpo de prova.

5.2.3 Fluido de Corte

Foram utilizados neste projeto, os seguintes fluidos de corte:

- ❖ Óleo emulsionável de base vegetal (a base de ésteres sintéticos), com especificação DMS 3200 F-1;
- ❖ Fluido sintético, com a especificação AGECOOL 939/B;

Em relação à emulsão de base vegetal (a base de ésteres sintéticos), este foi adotado no lugar do óleo mineral integral (que pode causar maiores problemas à saúde dos trabalhadores e meio ambiente), pois, segundo o fabricante, este tipo de fluido de corte é uma alternativa bastante promissora e adequada para processos de usinagem de aços endurecidos. A grande vantagem do óleo emulsionável vegetal à base de ésteres é que o mesmo apresenta alta lubricidade, aliado a um alto poder de refrigeração.

Já o fluido sintético é um refrigerante de base sintética aplicado amplamente nos processos de usinagem e retificação, apresentando os seguintes componentes em sua composição: agentes lubrificantes sintéticos; inibidores de corrosão; antiespumantes; coadjuvantes etc.

5.3 VARIÁVEIS DE SAÍDA

As variáveis de saída podem ser divididas em dois tipos: diretas e indiretas. As variáveis diretas são aquelas captadas em tempo real pelo sistema de aquisição de dados e gravadas no disco rígido do microcomputador. São estas: força tangencial de corte; emissão acústica; energia específica e parâmetro **DPO**. Já as variáveis indiretas são aquelas associadas à peça ou à ferramenta que foram medidas posteriormente. São estas: rugosidade, circularidade e desgaste diametral do rebolo.

5.3.1 Variáveis de Saída Direta

Para a determinação das variáveis de saída diretas (força tangencial de corte, parâmetro **DPO**, emissão acústica e energia específica), optou-se pela medição em tempo real da rotação (**RPM**) e da potência elétrica (**P_a**) consumida pelo motor de acionamento da ferramenta de corte. Como já mencionado, a rotação foi medida com um *encoder*, ou seja, um sensor de rotação acoplado ao eixo do motor de indução do cabeçote porta-rebolo. Este *encoder* enviava o valor de tensão proporcional à rotação diretamente para a placa A/D.

5.3.1.1 Medição da força tangencial de corte, energia específica de retificação e parâmetro DPO

A calibração da rotação do rebolo foi efetuada por meio de um tacômetro e um multímetro. Assim, variavam-se os valores de frequência do inversor enquanto se realizava uma leitura no tacômetro e no multímetro simultaneamente. Deste modo, a curva de calibração para a rotação do rebolo foi obtida, conforme a Figura 5.8.




Figura 5.8 – Curva de calibração da rotação.

Portanto a equação de calibração da rotação do rebolo é:

$$RPM = 2,6313V^2 + 270,7519V + 7,5303 \quad (5.1)$$

Onde:

RPM é rotação do rebolo calibrado em rpm; e

V é a tensão em Volts consumida pelo motor da máquina retificadora durante o processo.

Já a potência elétrica foi medida com a ajuda de um módulo de potência (*curvopower*) que envia um valor em Volts, proporcional à potência consumida pelo motor, para a placa de aquisição de dados. Esta placa A/D transforma os sinais analógicos em digitais.

A calibração da potência foi realizada por meio de uma curva de calibração que relaciona os valores de tensão na saída do módulo com a potência elétrica na saída do inversor de frequência. Esta curva foi construída com o auxílio de sete lâmpadas incandescentes de potência conhecida, as quais eram acopladas ao módulo. Assim, energizando uma após a outra e medindo com um multímetro a tensão na saída do módulo construiu-se a curva que é exibida na Figura 5.9.




Figura 5.9 – Curva de calibração do módulo de potência (*curvopower*).

Portanto a equação de calibração da potência elétrica é:

$$P_{el} = 883,87V - 13,236 \quad (5.2)$$

Onde:

P_{el} é a potência elétrica do circuito calibrado em Watts; e

V é a tensão em Volts consumida pelo motor da máquina retificadora durante o processo.

A calibração da potência de retificação (P) foi desenvolvida pelo Engenheiro Eletricista, Prof. Dr. Paulo Roberto de Aguiar. Esta calibração foi realizada por meio de curvas cedidas pelo fabricante de motor. A equação obtida é mostrada em seguida:

$$P = -2,3196 \times 10^{-8} P_{el}^3 + 1,6659 \times 10^{-4} P_{el}^2 + 0,53593 P_{el} - 28,3961 \quad (5.3)$$

Após a obtenção da potência mecânica, adquirimos a força tangencial de corte pela Equação 5.4:

$$F_t = \frac{60P}{d_s \text{ RPM} \pi} \quad (5.4)$$

Onde:

F_t é a força tangencial de corte (Newtons); e

d_s é o diâmetro do reboło (metros).

A fórmula utilizada para adquirir a energia específica de retificação é exibida a seguir, de acordo com MALKIN (1989).

$$u = \frac{F_t V_s}{\pi d_w V_f b} \quad (5.5)$$

Onde:

u é a energia específica de retificação (J/mm³);

V_s é a velocidade tangencial do rebolo (m/s);

b é a largura de retificação (mm);

V_w é a velocidade tangencial da peça (mm/s); e

a é a profundidade de retificação (mm).

O parâmetro **DPO**, como já mencionado no capítulo 4, é calculado pelo produto entre a média da potência elétrica consumida pelo motor no ciclo e o desvio-padrão do valor RMS da emissão acústica para o mesmo período (Equação 4.5).

5.3.1.2 Medição da emissão acústica (EA)

A emissão acústica foi medida por um sensor conectado a uma unidade de tratamento de sinais (*SENSIS*), que nada mais é, do que um condicionador de sinais. Esta unidade de tratamento calcula o valor RMS do sinal em Volts e o envia para a placa A/D. Foram utilizados como parâmetros constantes da unidade de tratamento de sinais durante todos os ensaios os seguintes itens:

- ❖ Ganho de sinal: 3;
- ❖ Redução de ruído: 30;
- ❖ Ganho de entrada: 3; e
- ❖ Constante de tempo: 1ms.

Após análise dos melhores locais para o posicionamento do sensor de emissão acústica, optou-se pelo seu posicionamento em um suporte criado para fixá-lo o mais próximo possível da peça, de forma a garantir a máxima eficiência na leitura dos seus valores. A Figura 5.10, mostra o posicionamento do sensor de emissão acústica na contra-ponta da máquina. Esta localização também impossibilita a interferência da vibração do motor e de outras fontes de ruído na captação da grandeza.




Figura 5.10 – Fixação do sensor de emissão acústica na contra-ponta da máquina retificadora.

5.3.1.3 O programa VI

O *software* de interface utilizado foi o LabVIEW 6.1 que comanda a placa A/D durante a aquisição e salva os dados separadamente em arquivos binários do tipo I16.

Foi construído um programa do LabVIEW, chamado de *VI* ou *virtual instrument*, para a interface usuário-computador onde os valores das grandezas medidas eram visualizados em tempo real. Este programa também tinha a função de gravar os dados nos diretórios escolhidos pelo operador.

A Figura 5.11 mostra a tela principal do *VI* com todos os mostradores ou *displays* de apresentação das grandezas medidas e seus respectivos campos de destino de gravação.




Figura 5.11 – Tela principal do programa de aquisição de dados (VI).

Após a gravação dos dados de potência elétrica e rotação, foi utilizado o *software* Matlab 6.5 para o cálculo da força tangencial de corte, do parâmetro **DPO** e da energia específica de corte correspondente a cada ensaio.

5.3.2 Variáveis de Saída Indireta

5.3.2.1 Medição da rugosidade e circularidade

A rugosidade foi medida com um rugosímetro modelo Surtronic 3+ e um *software* TalyProfile versão Lite 3.1.4, da marca *TAYLOR HOBSON*, ajustado para um comprimento de amostragem (*cut-off*) de 0,8 μm . Os valores de rugosidade foram medidos utilizando o parâmetro R_a (rugosidade média aritmética). A Figura 5.12 mostra a disposição dos equipamentos para a medição de rugosidade.




Figura 5.12 – Disposição dos equipamentos para a medição da rugosidade (R_a).

As medidas foram feitas para todas as peças. Cada peça teve a rugosidade medida em cinco posições distintas e aproximadamente equidistantes. Ao final das medições, foram obtidos os valores médios de cada peça e, em seguida, o valor médio das três repetibilidades referente a cada grupo de ensaios.

Para a medição da circularidade, utilizou-se o equipamento TALYROND 31C, do fabricante *TAYLOR HOBSON*. Na Figura 5.13, é possível observar todos os componentes do aparelho de medição.




Figura 5.13 – Equipamento TALYROND 31C, do fabricante *TAYLOR HOBSON*.

A peça foi fixada pelas castanhas da placa do equipamento, verificando-se a melhor posição de fixação. Foram executadas três medições em cada corpo de prova, em três posições distintas da espessura total da peça (3 mm). Portanto, foi realizado um deslocamento no eixo Z da máquina (vertical) de 1 mm entre cada medição. Ao final das medições, foram obtidos os valores médios de cada peça e, em seguida, o valor médio das três repetibilidades referente a cada grupo de ensaios. A Figura 5.14 mostra a fixação e a medição do erro de circularidade.




Figura 5.14 – Vista da fixação e medição do erro de circularidade.

É importante salientar que as medições de rugosidade e circularidade foram realizadas para todas as três repetibilidades. Portanto, não foram realizadas medições na face destinada à fixação da terceira repetibilidade, ou quarta região. A Figura 5.15 mostra a região das medições.




Figura 5.15 – Região das medições de circularidade e rugosidade.

5.3.2.2 Medição do desgaste diametral do rebolo

O desgaste diametral do rebolo foi analisado pelo método da impressão do perfil desgastado. Neste método, ao final de cada ensaio, um tarugo de aço SAE 1020, de diâmetro de 35 mm, era fixado no porta-peças da retificadora. O rebolo então retificava um determinado volume de material, penetrando uma profundidade de corte a_t igual a 300 μm . Como durante o processo de retificação, apenas uma parte da largura do rebolo é desgastada, a outra serve de referência para a medição do desgaste radial Δ_r , a ser verificado. Este fica impresso no tarugo, após o mergulho da ferramenta, conforme apresentado na Figura 5.16.




Figura 5.16 – Representação esquemática da medição do desgaste radial do rebolo.

Deste modo, utilizando o rugosímetro Surtronic 3+ como um medidor de perfil e também o *software* TalyProfile versão Lite 3.1.4 para a aquisição dos dados da saliência, foi possível a obtenção da distância entre o pico mais alto e o vale mais baixo com auxílio do parâmetro **Pt**. Este parâmetro (referente ao valor de desgaste radial) multiplicado por 2 (dois) resulta no valor de desgaste diametral $\Delta\varnothing$.

5.4 PLANEJAMENTO DOS ENSAIOS

Como já foi dito anteriormente, os ensaios de usinagem definitivos geraram dados que foram usados na RNA. Para isso, foram realizados ensaios preliminares para determinar as condições que seriam utilizadas nos ensaios definitivos. Portanto, os ensaios preliminares serviram basicamente para determinar o tipo de disposição do defletor (0°, 7,5°, 15° ou sem defletor) e o fluido de corte (emulsão ou solução), a serem utilizados.

As configurações dos defletores utilizados nesta fase do trabalho podem ser vistas na Figura 5.17.




Figura 5.17 – Desenho esquemático dos defletores utilizados nos ensaios preliminares.

5.4.1 Ensaios Preliminares

Nesta seção, são apresentados os ensaios preliminares realizados para a escolha do defletor aerodinâmico e do fluido de corte. Estes ensaios fazem parte de uma dissertação de mestrado desenvolvida em conjunto com este trabalho. No entanto, existem algumas diferenças no que diz respeito às condições de testes.

Os ensaios tiveram como parâmetros constantes: lubri-refrigeração otimizada com bocal de 4 mm (vazão de 22 l/min); 100 ciclos ou mergulhos; velocidade de avanço ou mergulho ($V_f = 1,5$ mm/min); profundidade de retificação ($a = 100$ μ m); rotação da peça ($n_w = 204$ rpm); tempo de *spark-out* (8 segundos); velocidade periférica do rebolo ($V_s = 30$ m/s); material da peça (VC-131); e rebolo de CBN (14A1 - SNB151Q12VR2).

Dentre os resultados obtidos, a força tangencial de corte e a energia específica de retificação foram utilizadas para a escolha da disposição do defletor e do fluido de corte. Estes resultados são provenientes da média aritmética das quatro repetibilidades realizadas nos ensaios preliminares. Foram feitos ensaios variando-se os tipos de fluido de corte : fluido sintético (solução) e óleo emulsionado (emulsão), ambos com concentração de 3,5%. E também a presença ou não de defletor. O defletor foi utilizado com três angulações distintas: 0°, 7,5° e 15°. As Figuras 5.18 a 5.21 são referentes aos valores de força tangencial de corte e energia específica de retificação, respectivamente.




Figura 5.18 – Força tangencial de corte utilizando óleo emulsionado.




Figura 5.19 – Força tangencial de corte utilizando fluido sintético.




Figura 5.20 – Energia específica de retificação utilizando óleo emulsionado.




Figura 5.21 – Energia específica de retificação utilizando fluido sintético.

Nas Figuras 5.18 a 5.21, pode-se observar que as condições onde foram obtidos menores valores de força foram com o defletor a 0° e $7,5^\circ$. A pior condição foi a sem defletor como era de se esperar, pois a camada de ar atrapalha consideravelmente a chegada de fluido de corte na região de contato, elevando assim os esforços de corte.

Analisando-se separadamente a força tangencial de corte nas Figuras 5.18 e 5.19, têm-se resultados melhores para o fluido de corte do tipo óleo emulsionado, ou emulsão e também o defletor 0° possui resultados ligeiramente melhores que o de $7,5^\circ$ e 15° . O mesmo ocorre para a energia específica de retificação nas Figuras 5.20 e 5.21.

5.4.2 Escolha dos Parâmetros para os Ensaios Definitivos

Com base nos gráficos apresentados nas Figuras 5.18 a 5.21, fica claro que dentre os dois fluidos testados, o melhor foi a emulsão pois esta apresenta valores de força tangencial de corte e energia específica menores do que o fluido sintético. Isto significa um maior poder de remoção de calor da região de corte.

A observação dos resultados dos ensaios nos quais foram utilizados defletores em comparação com os ensaios em que não se empregou defletor, mostra que a utilização deste aparato melhora significativamente a entrada do fluido de corte na região de retificação. Esta melhora fica evidente para a emulsão como já comentado anteriormente.

A escolha do defletor com angulação de 0° fica melhor justificada pelos gráficos das Figuras 5.18 e 5.20, onde se observam os menores valores de força tangencial de corte e energia específica.

Portanto, os parâmetros dos ensaios definitivos escolhidos foram os seguintes:

- ❖ Refrigeração otimizada com bocal de 3 mm (vazão de 12,8 l/min);
- ❖ 60 ciclos ou mergulhos no total;
- ❖ Profundidade de corte total $a = 200 \mu\text{m}$;
- ❖ 14 velocidades de avanço diferentes (V_f);
- ❖ Tempo de *spark-out* de 8 segundos;
- ❖ Velocidade periférica do rebolo $V_s = 30 \text{ m/s}$;
- ❖ Rotação da peça $n_w = 204 \text{ rpm}$;
- ❖ Defletor com angulação de 0° ;
- ❖ Óleo emulsionável (concentração: 3,5%);
- ❖ Material da peça VC-131; e
- ❖ Rebolo de CBN (14A1 - SNB151Q12VR2).

Como pode ser observado, o bocal utilizado nos ensaios definitivos foi de 3 mm. Esta mudança se deu pelo fato da bomba ter passado por uma revisão mecânica logo após os ensaios preliminares, onde vários componentes internos foram trocados. Deste modo, a sua eficiência foi melhorada significativamente, possibilitando a utilização de um bocal com diâmetro igual à largura de retificação de 3 mm (situação ideal). Isto foi feito respeitando a relação 1:1 entre a velocidade periférica do rebolo e a velocidade do fluido, deste modo, modificou-se a vazão para 12,8 l/min.

5.5 PROCEDIMENTOS PRELIMINARES

A peça foi fixada entre centros com a ajuda de um mandril comum, desta forma, antes do avivamento do rebolo para o início dos ensaios, realizou-se uma operação de uniformização da excentricidade da peça causada pela folga existente entre o mandril e a mesma. Desta forma, garantiu-se a uniformidade de contato entre o rebolo e a peça desde o primeiro mergulho.

Antes de cada ensaio, foram realizadas algumas operações referentes ao fluido e à ferramenta de corte, onde o objetivo foi manter todas as condições de corte constantes de um ensaio para outro. Estas operações foram o avivamento para o rebolo e o controle do pH e concentração do fluido de corte.

Também foi realizado o posicionamento do bocal ao longo da largura do rebolo, já que para os ensaios definitivos, foram utilizadas duas regiões do rebolo. Deste modo, cada avivamento foi feito depois de dois ensaios (um para cada região).

5.5.1 Afiação da Ferramenta de Corte

A afiação do rebolo superabrasivo foi executada com um dressador do tipo *fliese* de diamante. A operação foi realizada de maneira mais semelhante possível para não alterar a morfologia do rebolo de um ensaio para o outro.

Já que nos ensaios definitivos a velocidade de avanço variou, o desgaste do rebolo também possuiu diferenças entre os testes. Deste modo, visando economizar a camada de CBN do rebolo, foi utilizada uma penetração total de perfilamento diferente para cada ensaio, desde que, fosse constatado através do método de impressão do perfil do rebolo em um tarugo de aço SAE 1020 que esta penetração total eliminaria por completo a saliência. Além disso, foi sempre adotado a mesma regra de avanço, ou seja, avanços de 4 μm no começo e avanços de 2 μm nos últimos 10 μm .

5.5.2 Posicionamento do Defletor e Bocal

O defletor de 0° e o bocal de 3 mm utilizados nos ensaios foram montados de forma a permitir a movimentação do jato de fluido nas duas regiões usadas do rebolo. O desenho esquemático do bocal pode ser visto na Figura 5.22.




Figura 5.22 – Bocal de 3 mm de diâmetro de saída (dimensões básicas).

A Figura 5.23 apresenta uma vista da posição do defletor de 0° e do bocal em relação ao rebolo.




Figura 5.23 – Posição do defletor de 0° e do bocal em relação ao rebolo.

5.5.3 Ajuste do Fluido de Corte

O fluido de corte teve a sua concentração e nível de pH controlados, com valores de 3,5% e 9, respectivamente.

Os instrumentos destinados ao monitoramento dos fluidos de corte solúveis foram os seguintes: um peagômetro portátil marca *HANNA*, modelo Checker; e um refratômetro manual de bolso, marca *ATAGO*, modelo N-1E, utilizado para a medição da concentração dos fluidos de corte solúveis em água. A Figura 5.24 mostra estes aparelhos.




Figura 5.24 – Aparelhos (a) peagômetro portátil e (b) refratômetro manual.

Ressalta-se que antes da colocação do fluido de corte no reservatório da máquina, o mesmo foi cuidadosamente lavado, desinfetado e seco.

5.6 ENSAIOS DE USINAGEM

Os ensaios de usinagem foram definidos de acordo com os ensaios preliminares. Deste modo, com a definição do fluido de corte e o tipo de disposição do defletor, foi possível efetuar a classificação dos mesmos.

Os ensaios definitivos adotados tiveram duração de 60 ciclos e entre cada ciclo um tempo de centelhamento de 8 segundos. Cada ciclo, ou mergulho, tem profundidade total de corte de 0,2 mm. Deste modo, cada peça sofre uma redução de 12 mm em seu diâmetro.

5.6.1 Classificação dos Ensaios de Usinagem

O esquema dos ensaios realizados neste trabalho pode ser visto no fluxograma da Figura 5.25.




Figura 5.25 – Fluxograma dos ensaios definitivos (velocidades em milímetros por minuto).

Os ensaios realizados foram numerados de 1 a 42, conforme a figura anterior, sendo que a disposição destes pode ser verificada na Tabela 5.2 a seguir.

Tabela 5.2 – Disposição dos ensaios de usinagem.

Ensaio	Ensaio de Usinagem	Velocidade (mm/min)
E01 – E02 – E03	1	0,1
E04 – E05 – E06	2	0,2
E07 – E08 – E09	3	0,3
E10 – E11 – E12	4	0,4
E13 – E14 – E15	5	0,5
E16 – E17 – E18	6	0,6
E19 – E20 – E21	7	0,7
E22 – E23 – E24	8	0,8
E25 – E26 – E27	9	0,9
E28 – E29 – E30	10	1,0
E31 – E32 – E33	11	1,25
E34 – E35 – E36	12	1,5
E37 – E38 – E39	13	1,75
E40 – E41 – E42	14	2,0

5.6.2 Descrição dos Ensaio de Usinagem

Antes de cada ensaio, foram realizados os procedimentos preliminares, conforme já descrito, para a verificação da concentração e pH do fluido. Caso os mesmos não estivessem nas condições desejadas, procedimentos de correção eram adotados, até que se atingisse os valores pré-estabelecidos. A ferramenta superabrasiva foi afiada e o sistema de aquisição preparado para o início dos ensaios.

Como pôde ser verificado na Figura 5.9 da seção 5.2.3, o corpo de prova possui duas regiões de retificação. Deste modo, ajustou-se a primeira região do corpo de prova com a primeira região do rebolo.

Ligou-se o rebolo e com o auxílio de um conversor de frequência, manteve-se a velocidade tangencial do rebolo (V_s) em 30 m/s.

A vazão do fluido foi regulada por meio de um medidor de vazão do tipo turbina modelo DMY-2030, da marca CONTECH, de acordo com a Figura 5.26. Este medidor é colocado na saída da bomba que escoo o fluido de corte para o bocal. A vazão foi regulada para que a velocidade do fluido na saída do bocal fosse sempre de 30 m/s para satisfazer a relação de lubri-refrigeração 1:1. Deste modo, a vazão foi regulada em 12,8 l/min.




Figura 5.26 – Medidor de vazão DMY-2030, da marca CONTECH.

Depois disso, o jato era posicionado para a região de contato peça-rebolo. Com tudo pronto, o programa VI do LabVIEW foi acionado de forma a iniciar a aquisição e, logo em seguida, ligava-se o programa CNC da máquina. A Figura 5.27 exhibe a realização do ensaio com o jato de fluido devidamente posicionado.




Figura 5.27 – Ensaio sendo realizado na primeira região do corpo de prova.

Após a primeira repetibilidade o rebolo foi ajustado para que a sua segunda região entrasse em contato com a segunda região do corpo de prova. Também foi ajustado o jato de fluido para a nova região de contato peça-rebolo. Deste modo, a segunda repetibilidade pôde ser iniciada.

Com o término deste ensaio, trocou-se a peça ensaiada por outra nova e realizou-se a uniformização das duas regiões da mesma. Assim, pôde-se dar início à afiação do rebolo para o início da terceira e última repetibilidade do grupo. A terceira repetibilidade ocorria na região equivalente à primeira repetibilidade.

A quarta região, análoga à segunda região do primeiro corpo de prova, também foi retificada para que não houvesse erro na medição da circularidade referente à terceira repetibilidade, pois a fixação para a medição da mesma seria realizada na quarta região.

Após o término da retificação da quarta região, e conseqüentemente o término dos ensaios do grupo, iniciou-se os testes do próximo grupo de ensaios de usinagem de forma análoga ao descrito acima. Sempre com o cuidado de verificar todas as particularidades dos ensaios, promovendo assim, as mesmas condições entre todos os experimentos.

5.6.3 Procedimentos Pós-ensaios

Após a conclusão dos ensaios de usinagem, foram efetuadas as medições de circularidade, rugosidade e desgaste diametral do rebolo, e também os cálculos das variáveis de saída direta, assim como a elaboração de todos os respectivos gráficos. Desta forma, obteve-se todos os parâmetros necessários para o início do modelamento das redes neurais artificiais e a implementação das mesmas.

5.7 MODELAMENTO DAS REDES NEURAIS ARTIFICIAIS

Com todos os dados medidos dos ensaios de usinagem, pôde-se iniciar o modelamento das redes neurais escolhidas. Nesta 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. Sendo que para isso, foram testados modelos de RNA's com seis disposições diferentes de dados de entrada.

Estas disposições 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.

É importante ressaltar que nesta fase da pesquisa foi utilizado apenas o *software* Matlab 6.5, conforme anunciado anteriormente.

5.7.1 Dados de Entrada

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

- ❖ A força tangencial de corte (F_t);
- ❖ A emissão acústica (**EA**);
- ❖ A energia específica de retificação (**u**);
- ❖ O parâmetro **DPO**;
- ❖ O desgaste diametral do rebolo ($\Delta\emptyset$);
- ❖ A circularidade; e
- ❖ A rugosidade.

O conjunto de dados utilizados como entrada da RNA foi formado com a adição da velocidade de avanço do rebolo (V_f).

Como o objetivo do presente trabalho é a predição da circularidade e rugosidade da peça, todas as outras variáveis servirão como dados de entrada da RNA e apenas a circularidade e rugosidade como dados de saída.

A Figura 5.28 mostra esta divisão das variáveis utilizadas como valores de entrada e saída da rede neural artificial.




Figura 5.28 – Variáveis utilizadas como dados de entrada e saída da RNA.

Estes dados de entrada foram dispostos em grupos, nos quais cada um apresenta um conjunto diferente de dados. Isto foi feito para determinar o grau de importância de algumas destas variáveis na predição. A Figura 5.29 apresenta os três grupos de dados de entrada escolhidos para o presente trabalho.




Figura 5.29 – Grupos de dados de entrada da RNA.

Portanto, foram utilizados três grupos de dados de entrada. Para todos os grupos, os dados de saída foram a circularidade e a rugosidade.

Foram utilizadas duas base de dados nesta pesquisa e para a devida distinção adotou-se as seguintes denominações: base de dados **A** e base de dados **B**.

A diferença entre estas bases de dados está nas variáveis diretas: força tangencial de corte (**F_t**), emissão acústica (**EA**), energia específica de retificação (**u**) e parâmetro **DPO**.

Como já foi comentado, esta pesquisa estudou o comportamento dos últimos 40 ciclos de retificação para as variáveis diretas citadas acima. Também foi analisado o valor médio

destes 40 ciclos para todas estas variáveis. Estes gráficos são comentados no próximo capítulo.

Contudo, como o objetivo é que estes valores sejam utilizados no modelamento da rede neural, pode-se conceber dois tipos de base de dados diferentes: uma com o conjunto das médias dos valores dos 40 ciclos (base de dados **A**), e portanto constituída por 14 conjuntos de dados (um para cada velocidade de avanço); e outra com todos os valores dos 40 ciclos, ou seja, 560 conjuntos de dados (40 conjuntos para cada uma das 14 velocidades de avanço).

Desta forma, adota-se para a segunda base de dados (**B**), cada ciclo (dos 40) como se fosse um ensaio realizado.

Estas diferenças entre as bases de dados podem ser vistas na Figura 5.30.




Figura 5.30 – Diferença entre a base de dados **A** e **B**.

Portanto, tem-se a seguinte composição:

- ❖ **Base de dados A:** referente à base de dados onde os valores de entrada da RNA são os valores médios de todos os 40 ciclos finais para a força tangencial de corte (**F_t**), emissão acústica (**EA**), energia específica de retificação (**u**) e parâmetro **DPO**; e

- ❖ **Base de dados B:** referente à base de dados onde os valores de entrada da RNA são todos os valores de cada um dos 40 ciclos finais para a força tangencial de corte (F_t), emissão acústica (EA), energia específica de retificação (u) e parâmetro **DPO**. Deve ser observado que os valores de cada um dos 40 ciclos mencionados aqui são os valores médios das três repetibilidades.

A base de dados **B** deve ser observada com atenção, pois as variáveis: desgaste diametral do rebolo ($\Delta\emptyset$); circularidade; e rugosidade, não foram medidas em cada um dos 40 ciclos, mas sim no final do ensaio (último ciclo).

Entretanto, pode-se considerar os valores de circularidade e rugosidade da peça constantes durante estes últimos 40 ciclos, pois a variação real é mínima. Já o desgaste diametral do rebolo ($\Delta\emptyset$) pode ter a sua variação calculada de um ciclo para o outro, pois o desgaste é zero no começo e igual ao valor medido no último ciclo, ou seja, com o valor final é possível calcular os valores para cada um dos 40 ciclos finais (de um total de 60). De acordo com estas considerações, as Tabela 5.3 e 5.4 mostram as base de dados **A** e **B** respectivamente.

Tabela 5.3 – Base de dados **A** com 14 conjuntos (um para cada V_f).

	Dados de Entrada da RNA						Dados de Saída da RNA	
	DPO	F_t	EA	u	V_f	$\Delta\emptyset$	Circularidade	Rugosidade
Média dos 40 ciclos	$DPO_{0,1}$	$F_{t\,0,1}$	$EA_{0,1}$	$u_{0,1}$	0,1	$\Delta\emptyset_{0,1}$	$O_{0,1}$	$R_{a0,1}$
Média dos 40 ciclos	$DPO_{0,2}$	$F_{t\,0,2}$	$EA_{0,2}$	$u_{0,2}$	0,2	$\Delta\emptyset_{0,2}$	$O_{0,2}$	$R_{a0,2}$
Média dos 40 ciclos	$DPO_{0,3}$	$F_{t\,0,3}$	$EA_{0,3}$	$u_{0,3}$	0,3	$\Delta\emptyset_{0,3}$	$O_{0,3}$	$R_{a0,3}$
Média dos 40 ciclos	.	.	.	.	.	.	.	.
Média dos 40 ciclos	$DPO_{2,0}$	$F_{t\,2,0}$	$EA_{2,0}$	$U_{2,0}$	2,0	$\Delta\emptyset_{2,0}$	$O_{2,0}$	$R_{a2,0}$

Tabela 5.4 – Base de dados **B** com 560 conjuntos (40 para cada V_f).

	Dados de Entrada da RNA						Dados de Saída da RNA	
	DPO	F_t	EA	u	V_f	$\Delta\emptyset$	Circularidade	Rugosidade
1º ciclo ao 40º ciclo	.	.	.	.	0,1	.	$O_{0,1}$	$R_{a0,1}$
1º ciclo ao 40º ciclo	.	.	.	.	0,2	.	$O_{0,2}$	$R_{a0,2}$
1º ciclo ao 40º ciclo	.	.	.	.	0,3	.	$O_{0,3}$	$R_{a0,3}$
1º ciclo ao 40º ciclo	.	.	.	.	.	.	.	.
1º ciclo ao 40º ciclo	.	.	.	.	2,0	.	$O_{2,0}$	$R_{a2,0}$

5.7.2 Configuração das Redes Neurais Artificiais

Finalmente, de posse destas informações, foram definidas seis diferentes combinações de dados, e portanto, seis diferentes redes neurais artificiais. Estas RNA's foram obtidas com a combinação dos três grupos e duas bases de dados da acordo com a Tabela 5.5.

Tabela 5.5 – RNA's que foram utilizadas neste trabalho.

BASE DE DADOS	GRUPO	RNA
A	I	MLP - A _I
A	II	MLP - A _{II}
A	III	MLP - A _{III}
B	I	MLP - B _I
B	II	MLP - B _{II}
B	III	MLP - B _{III}

5.7.3 Escolha dos Parâmetros dos Testes

As seis RNA's utilizadas foram definidas com apenas uma única camada oculta. Isto pode ser explicado pelo *Teorema aproximador de funções*, visto no capítulo 4, que afirma ser necessária apenas uma camada oculta para um *perceptron* de múltiplas camadas computar uma aproximação uniforme para um dado conjunto de treinamento (HAYKIN, 2001).

No entanto, foi necessária a realização de testes para determinar a quantidade de neurônios para a camada oculta de cada RNA.

Para estes testes, o *software* Matlab 6.5 foi utilizado com os seguintes comandos:

- ❖ **newff**: comando para uso da rede neural MLP *back-propagation*;
- ❖ **tansig**: função de ativação dos neurônios da camada interna;
- ❖ **purelin**: função de ativação dos neurônios da última camada;
- ❖ **traingd**: algoritmo de treinamento gradiente de descida;
- ❖ **postmnmx**: todos os dados utilizados nas RNA's foram normalizados;
- ❖ **train**: comando de treinamento da RNA; e
- ❖ **sim**: comando de simulação da RNA.

Foram escolhidos os seguintes parâmetros de treinamento:

- ❖ Treinamento *back-propagation*;
- ❖ Treinamento para 4.000 épocas;
- ❖ Valor do erro médio quadrado: 1×10^{-5} ; e
- ❖ Taxa de aprendizagem: 0,4.

5.7.4 Determinação da Camada Oculta

Para a determinação da quantidade de neurônios da camada oculta, foram construídas RNA's com quantidades diferentes de neurônios na camada interna. Cada tipo de RNA foi treinado e simulado 10 vezes com os mesmos dados (treinamento e validação).

Cada treinamento foi realizado com a RNA inicializada, ou seja, os pesos e *bias* foram zerados antes de cada treinamento. Em seguida, as RNA's foram simuladas com outros dados (dados de validação).

A Tabela 5.6 apresenta a divisão dos dados provindos dos ensaios de usinagem para as RNA's que utilizam a base de dados **A**. Desta forma, foram empregados 11 conjuntos de dados para o treinamento e três para a validação.

Para as três RNA's restantes, que utilizam a base de dados **B**, foi feita uma seleção dos conjuntos de dados utilizados no treinamento e na validação. Esta seleção teve como princípio utilizar 75% dos conjuntos disponíveis no treinamento e os 15% restantes na validação das RNA's. Desta forma, as redes neurais desta base de dados utilizaram 420 conjuntos para o treinamento e 140 para a validação. Foram utilizados portanto, 10 conjuntos de cada velocidade de avanço na validação. A Tabela 5.7 mostra a disposição dos dados para as redes que utilizam a base de dados **B**. Devido ao grande número de conjuntos (560), esta tabela

exibe apenas a disposição dos dados para uma velocidade de avanço (40 conjuntos), sendo esta distribuição igual para as demais velocidades.

Tabela 5.6 – Disposição dos dados de treinamento e validação da base de dados **A**.

Ensaio de Usinagem	Treinamento	Validação
1	X	
2	X	
3		X
4	X	
5	X	
6	X	
7		X
8	X	
9	X	
10	X	
11		X
12	X	
13	X	
14	X	

Tabela 5.7 – Exemplo da distribuição dos dados de treinamento e validação da base de dados **B** para cada velocidade de avanço.

Ciclo	Treinamento	Validação	Ciclo	Treinamento	Validação
1° ~ 3°	X		21° ~ 23°	X	
4°		X	24°		X
5° ~ 7°	X		25° ~ 27°	X	
8°		X	28°		X
9° ~ 11°	X		29° ~ 31°	X	
12°		X	32°		X
13° ~ 15°	X		33° ~ 35°	X	
16°		X	36°		X
17° ~ 19°	X		37° ~ 39°	X	
20°		X	40°		X

Como pode ser observado na Tabela 5.6, foram escolhidas as velocidades de avanço 0,3; 0,7 e 1,25 mm/min para os dados de validação pois estes são os valores intermediários da faixa de velocidades de mergulho utilizada nesta pesquisa.

Foi determinado que cada RNA iria ser treinada e simulada (10 vezes) com diferentes números de neurônios na camada oculta. Assim, com a média dos resultados das simulações, foi determinado o número ideal de neurônios da camada intermediária.

Optou-se por variar a camada oculta de 4 a 12 neurônios para cada RNA citada na Tabela 5.5. Desta forma, foram feitos 90 treinamentos e simulações para cada RNA, em um total de 540 treinamentos e simulações para esta fase da pesquisa. A Tabela 5.8 apresenta as configurações testadas nesta fase para cada RNA.

Tabela 5.8 – Parâmetros utilizados na escolha da camada oculta de cada RNA.

RNA	Número de entradas	Número de neurônios da camada oculta	Treinamento + Simulação	Análise dos resultados
MLP - A _I	4	4 ~12	10 vezes	Média dos erros das saídas das RNA's (%)
MLP - A _{II}	5	4 ~12	10 vezes	Média dos erros das saídas das RNA's (%)
MLP - A _{III}	6	4 ~12	10 vezes	Média dos erros das saídas das RNA's (%)
MLP - B _I	4	4 ~12	10 vezes	Média dos erros das saídas das RNA's (%)
MLP - B _{II}	5	4 ~12	10 vezes	Média dos erros das saídas das RNA's (%)
MLP - B _{III}	6	4 ~12	10 vezes	Média dos erros das saídas das RNA's (%)

A Figura 5.31 exibe como exemplo o gráfico de um treinamento feito para uma RNA da base de dados **A**. Nesta figura o eixo das abscissas representa o número de épocas e o eixo das ordenadas o erro médio quadrado.




Figura 5.31 – Exemplo de treinamento para RNA com base de dados **A**.

A escolha do número de neurônios da camada interna para cada RNA testada foi baseada no erro médio (porcentagem) entre os resultados das simulações e os valores reais medidos das variáveis de saída (circularidade e rugosidade). Também foram utilizados os valores do coeficiente de correlação (**R**) de cada variável de saída.

5.8 COMPARAÇÃO FINAL ENTRE AS RNA's

Com o número de neurônios da camada oculta selecionado, e por sua vez, com as redes neurais definidas, foram realizados os ensaios que serviram para a comparação entre as redes neurais artificiais. As Figuras 5.32 e 5.33 mostram as configurações finais de cada RNA.




Figura 5.32 – Configuração final das redes neurais artificiais: (a) MLP-A_I-4x11x2; (b) MLP-A_{II}-5x8x2; e (c) MLP-A_{III}-6x9x2.




Figura 5.33 – Configuração final das redes neurais artificiais: (a) **MLP-B_I-4x11x2**; (b) **MLP-B_{II}-5x12x2**; e (c) **MLP-B_{III}-6x10x2**.

Estes ensaios tiveram como dados constantes os seguintes itens:

- ❖ Rede neural MLP *back-propagation*;
- ❖ Função de ativação sigmoideal dos neurônios da camada oculta;
- ❖ Função de ativação linear dos neurônios da última camada;
- ❖ Algoritmo de treinamento tipo gradiente de descida;
- ❖ Todos os dados utilizados nas RNA's foram normalizados;
- ❖ Treinamento para 4000 épocas;

- ❖ Valor do erro médio quadrado: 1×10^{-5} ; e
- ❖ Taxa de aprendizagem: 0,4.

Primeiramente, foram realizados os treinamentos para todas as seis redes neurais. Cada treinamento foi feito com todos os dados disponíveis. Desta forma, as RNA's que utilizaram a base de dados **A**, foram treinadas com todos estes dados. O mesmo foi feito com as RNA's que utilizaram a base de dados **B**. Após o treinamento, as redes neurais artificiais foram simuladas com todos os dados das respectivas bases de dados.

Este procedimento de treinamento e simulação foi repetido 10 vezes para cada RNA, sendo que foi utilizada apenas a repetibilidade com o melhor resultado de cada rede neural.

Assim como na fase anterior, de escolha do número de neurônios da camada oculta, os parâmetros utilizados para a comparação final das RNA's foram:

- ❖ os erros médios da circularidade e rugosidade entre os resultados da RNA (saídas das RNA's) e os valores reais (medidos); e
- ❖ a regressão linear dos resultados para cada rede neural.

6 RESULTADOS E DISCUSSÕES

Este item apresenta os resultados obtidos nos ensaios realizados nesta pesquisa. Deste modo, são exibidos os resultados dos ensaios de usinagem e também dos testes desempenhados com as redes neurais artificiais.

Foram feitas ainda discussões acerca dos dados obtidos, em especial dos provenientes das RNA's utilizadas.

6.1 RESULTADOS DOS ENSAIOS DE USINAGEM

Neste item são apresentados os gráficos de: força tangencial de corte (F_t), energia específica de retificação (u), emissão acústica (EA), parâmetro **DPO**, desgaste diametral do rebolo ($\Delta\emptyset$), rugosidade e circularidade.

Como já mencionado no capítulo 5, foram realizados 60 ciclos em cada ensaio. No entanto, utilizou-se para a confecção dos gráficos de força tangencial de corte, energia específica, emissão acústica e parâmetro **DPO** os valores máximos dos últimos 40 ciclos. Isto foi feito para eliminar o início dos valores que são altos e direcionar a discussão dos resultados apenas para os valores finais de cada ciclo que estão mais próximos de valores constantes.

Esta diminuição está relacionada com o uso do rebolo de CBN nos ensaios, onde é comum uma redução gradativa dos valores das variáveis citadas, tendendo a um valor constante. Isto ocorre pois, mesmo após a afiação da ferramenta, alguns dos seus grãos de CBN ainda se encontram sem arestas de corte, provocando assim, altos valores no início do ensaio. No entanto, devido a friabilidade dos grãos abrasivos e a capacidade de auto-afiação do rebolo de CBN, a renovação das arestas de corte (microefeito) produz esforços cada vez menores tendendo a um valor constante (MALKIN, 1989).

Portanto, este comportamento não poderá ser observado nos gráficos apresentados a seguir, pois, como já foi dito, os gráficos de força tangencial de corte, energia específica de retificação, emissão acústica e parâmetro **DPO** possuem apenas os valores máximos dos últimos 40 ciclos, ou seja, representam apenas os valores constantes do final de cada ensaio.

Todos os resultados obtidos para as variáveis de saída direta foram subtraídos dos seus respectivos valores em vazio, adquiridos no momento anterior ao início do avanço ou mergulho do rebolo na peça.

6.1.1 Força Tangencial de Corte (F_t)

A primeira variável analisada neste trabalho é a força tangencial de corte. Esta é de grande importância na avaliação do mecanismo de corte.

Inicialmente os gráficos desta variável são apresentados separados pelo grupo de ensaio, ou seja, um gráfico para cada velocidade de avanço. Nestes gráficos estão todos os ensaios do grupo (três repetibilidades). Portanto, cada gráfico contém as três repetibilidades e também a média destes três ensaios. Os gráficos estão dispostos nas Figuras 6.1 a 6.14.




Figura 6.1 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,1 mm/min.




Figura 6.2 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,2 mm/min.




Figura 6.3 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,3 mm/min.




Figura 6.4 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,4 mm/min.




Figura 6.5 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,5 mm/min.




Figura 6.6 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,6 mm/min.




Figura 6.7 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,7 mm/min.




Figura 6.8 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,8 mm/min.




Figura 6.9 – Força tangencial de corte para a velocidade de avanço (V_f) de 0,9 mm/min.




Figura 6.10 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,0 mm/min.




Figura 6.11 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,25 mm/min.




Figura 6.12 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,5 mm/min.




Figura 6.13 – Força tangencial de corte para a velocidade de avanço (V_f) de 1,75 mm/min.




Figura 6.14 – Força tangencial de corte para a velocidade de avanço (V_f) de 2,0 mm/min.

De acordo com as Figuras 6.1 a 6.14, pode-se notar que a característica principal do acréscimo da velocidade de avanço é o aumento da força tangencial de corte. Isso pode ser explicado pela fórmula da Equação 5.4, que relaciona a força tangencial de corte (F_t) com a potência mecânica (P).

Quando ocorre o aumento da velocidade de mergulho do rebolo em direção à peça, ocorre também uma maior resistência ao movimento de rotação do rebolo devido ao maior contato deste com a peça. Esta resistência gera um aumento da potência elétrica consumida pelo motor de acionamento da ferramenta que, por sua vez, gera um aumento da potência mecânica. Deste modo, como a potência mecânica é diretamente proporcional à força tangencial, esta também acaba sofrendo um acréscimo.

Observando as figuras é possível perceber que a dispersão entre as repetibilidades do mesmo grupo tende a diminuir com o aumento da velocidade de mergulho. Outro fenômeno explícito nos gráficos é a maior variação dos valores do mesmo ensaio para menores velocidades de avanço. Isto pode ser explicado pelo tempo total de cada ciclo, já que este tempo varia de um grupo de experimentos para outro, uma vez que a profundidade de cada mergulho é constante para todos os ensaios.

Para o primeiro grupo por exemplo, onde a velocidade de avanço é 0,1 milímetros por minuto, o tempo total de cada ciclo é de dois minutos e oito segundos (somado o tempo de *spark-out*). Já para o último grupo, onde a velocidade de avanço é de 2,0 milímetros por minuto, o tempo total de cada ciclo é de apenas quatorze segundos. Ou seja, enquanto no primeiro grupo o rebolo avança na peça durante dois minutos, no último grupo este tempo é de somente seis segundos.

Portanto, quando o tempo efetivo de retificação (sem contar com o centelhamento) é elevado, como no caso do primeiro grupo, o valor da força tangencial de corte oscila em uma faixa. Esta oscilação pode ser explicada pela rigidez do conjunto máquina-ferramenta-peça, ou também pelas características topográficas do rebolo.

Como já mencionado anteriormente, os valores da força tangencial de corte foram utilizados como *input*, ou dados de entrada, da RNA. Deste modo, valendo-se apenas da curva da força média de cada grupo, foi calculada a média destes valores, ou seja, a curva foi representada por apenas um único valor, a média de todos os 40 ciclos. Este gráfico está apresentado na Figura 6.15.




Figura 6.15 – Valor médio da força tangencial de corte para todas as velocidades de avanço.

Pela Figura 6.15, nota-se que os valores da força tangencial de corte, com o aumento da velocidade de avanço, aumentam até um certo ponto e depois se conservam em um patamar ligeiramente menor. Este comportamento demonstra que a variação da força de corte não é linear, ou seja, com o acréscimo da velocidade de mergulho, o aumento da força se dá até um certo ponto e depois se conserva em um mesmo valor ou faixa.

Fica evidente que se trata apenas de uma tendência aparente, pois o que se percebe pela Figura 6.15 é que em alguns ensaios, principalmente nos de velocidade 0,8 e 1,75 mm/min, os valores de força ficam fora da tendência citada.

Uma explicação para estes valores diferentes do comportamento esperado pode ser o avivamento, já que este foi realizado de forma manual. Pois, mesmo o máximo de cuidado possível na sua realização não é suficiente para que um seja igual ao outro. Deste modo, algumas pequenas disparidades podem ocorrer. Esta explicação também esclarece as mesmas características encontradas nas outras variáveis mostradas a seguir.

6.1.2 Energia Específica de Retificação (u)

A energia específica de retificação (u) pode ser definida como a energia necessária para remover uma unidade de volume do material (MALKIN, 1989). Esta energia é uma variável de saída do processo relacionada com a força tangencial de corte (F_t), a velocidade tangencial do rebolo (V_s), o diâmetro da peça (d_w), a largura de retificação (b) e a velocidade de avanço (V_f). Os gráficos obtidos foram plotados com os valores obtidos do cálculo da Equação 5.5 e estão apresentados em J/mm³.

Para esta análise, foi utilizado a mesma disposição dos gráficos de força tangencial de corte no item 6.1.1. Ou seja, nas figuras iniciais, cada gráfico contém as três repetibilidades do referido grupo e também a média destes três ensaios.

As Figuras 6.16 a 6.29 nos mostram a primeira série de gráficos onde é possível visualizar o comportamento das repetibilidades de cada grupo.




Figura 6.16 – Energia específica para a velocidade de avanço (V_f) de 0,1 mm/min.




Figura 6.17 – Energia específica para a velocidade de avanço (V_f) de 0,2 mm/min.




Figura 6.18 – Energia específica para a velocidade de avanço (V_f) de 0,3 mm/min.




Figura 6.19 – Energia específica para a velocidade de avanço (V_f) de 0,4 mm/min.




Figura 6.20 – Energia específica para a velocidade de avanço (V_f) de 0,5 mm/min.




Figura 6.21 – Energia específica para a velocidade de avanço (V_f) de 0,6 mm/min.




Figura 6.22 – Energia específica para a velocidade de avanço (V_f) de 0,7 mm/min.




Figura 6.23 – Energia específica para a velocidade de avanço (V_f) de 0,8 mm/min.




Figura 6.24 – Energia específica para a velocidade de avanço (V_f) de 0,9 mm/min.




Figura 6.25 – Energia específica para a velocidade de avanço (V_f) de 1,0 mm/min.




Figura 6.26 – Energia específica para a velocidade de avanço (V_f) de 1,25 mm/min.




Figura 6.27 – Energia específica para a velocidade de avanço (V_f) de 1,5 mm/min.




Figura 6.28 – Energia específica para a velocidade de avanço (V_f) de 1,75 mm/min.




Figura 6.29 – Energia específica para a velocidade de avanço (V_f) de 2,0 mm/min.

De acordo as Figuras 6.16 a 6.29, pode-se notar que os valores de energia específica, diferentemente da força de corte, diminuem com o aumento da velocidade de mergulho.

Isto pode ser explicado pela fórmula da Equação 5.5, onde a energia específica (u) é diretamente proporcional à força tangencial de corte (F_t) e inversamente proporcional à velocidade de mergulho (V_f). Além disto, a velocidade de mergulho aumenta em uma maior proporção do que o aumento da força de corte, fazendo com que o valor da energia específica diminua progressivamente.

Pode-se observar também a ocorrência da diminuição da dispersão entre as repetibilidades do mesmo grupo com o aumento da velocidade de mergulho, como ocorre com a força de corte. Do mesmo modo, ocorre a grande variação dos valores no mesmo ensaio para as menores velocidades de avanço. A explicação é a mesma, ou seja, a diferença do tempo total de cada ciclo, já que a energia específica de retificação é derivada da força tangencial de corte.

Novamente, valendo-se apenas da curva da energia específica média de cada grupo, foi calculada a média destes valores, ou seja, a média de todos os 40 ciclos (Figura 6.30).




Figura 6.30 – Valor médio da energia específica de retificação para todas as velocidades de avanço.

Pelo gráfico da Figura 6.30, percebe-se que os valores de energia específica diminuem com o aumento da velocidade de mergulho. Isto já foi explicado nos gráficos anteriores.

Fazendo uma analogia aos resultados da força tangencial de corte, os valores de energia específica possuem um comportamento mais próximo do linear, no entanto, este decréscimo sofre uma leve atenuação com o aumento da velocidade de avanço. Portanto, como a força de corte, o comportamento da energia específica tende a um mesmo valor ou faixa.

6.1.3 Emissão Acústica (EA)

A emissão acústica (EA) é caracterizada como uma energia resultante da interação entre o grão abrasivo e a peça, que se propaga através da estrutura do material e da máquina.

Os gráficos da emissão acústica são apresentados separados pelo grupo de ensaio, ou seja, um gráfico para cada velocidade de avanço. Cada gráfico possui os valores de todas as repetibilidades, além do valor médio destas (Figuras 6.31 a 6.44).




Figura 6.31 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,1 mm/min.




Figura 6.32 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,2 mm/min.




Figura 6.33 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,3 mm/min.




Figura 6.34 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,4 mm/min.




Figura 6.35 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,5 mm/min.




Figura 6.36 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,6 mm/min.




Figura 6.37 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,7 mm/min.




Figura 6.38 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,8 mm/min.




Figura 6.39 – Emissão acústica RMS para a velocidade de avanço (V_f) de 0,9 mm/min.




Figura 6.40 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,0 mm/min.




Figura 6.41 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,25 mm/min.




Figura 6.42 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,5 mm/min.




Figura 6.43 – Emissão acústica RMS para a velocidade de avanço (V_f) de 1,75 mm/min.




Figura 6.44 – Emissão acústica RMS para a velocidade de avanço (V_f) de 2,0 mm/min.

Como já foi mencionado anteriormente, os fenômenos relacionados à geração deste sinal são: a fratura do grão abrasivo; a fratura do ligante; e o atrito entre o grão e a peça (BIFFI, 2003).

A emissão acústica, assim como a força tangencial, aumentou com o acréscimo da velocidade de mergulho do rebolo na peça. Isto acontece devido à maior intensidade destes fenômenos relacionados à geração do sinal de emissão acústica quando se dá o aumento da velocidade de avanço. Portanto, quanto maior for a velocidade de avanço maior será a emissão acústica.

Pela análise das Figuras 6.31 a 6.44, ficam evidentes duas características destes valores: ao mesmo tempo em que uma mesma repetibilidade possui pouca variação ao longo do ensaio; repetibilidades do mesmo grupo possuem grandes diferenças entre si, aumentando assim o desvio-padrão. Esta última ocorre com maior frequência para maiores valores de velocidade de avanço, citando como exemplo, os ensaios E37 e E41 das duas últimas velocidades de avanço.

Comportamentos deste tipo podem ser explicados pelo avivamento do rebolo entre um ensaio e outro. Visto que por mais minucioso que seja, o fato de ter sido realizado manualmente provoca uma certa diferença entre a topografia de um ensaio e outro, que pode

gerar pequenas disparidades nos valores obtidos. No entanto, são realizadas três repetibilidades para cada condição de ensaio.

A Figura 6.45 apresenta a média dos 40 ciclos dos valores das curvas médias de cada grupo.




Figura 6.45 – Valor médio da emissão acústica RMS para todas as velocidades de avanço.

Segundo o gráfico da Figura 6.45, pode-se perceber a tendência já mencionada anteriormente. Pois, com o aumento da velocidade de avanço, os valores aumentam mas esta taxa de aumento tende a diminuir, indicando assim uma estabilização dos valores.

As velocidades de 0,8 e 0,9 mm/min, assim como as de 1,75 e 2,0 mm/min, ficaram abaixo da tendência mencionada. Isto também pode ser explicado pela afiação rebolo, realizada manualmente.

6.1.4 Parâmetro DPO

Este parâmetro foi inicialmente idealizado para a detecção da queima no processo de retificação. As Figuras 6.46 a 6.59 exibem os gráficos para cada velocidade de mergulho. Estes contêm as três repetibilidades e a média destes três ensaios.




Figura 6.46 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,1 mm/min.




Figura 6.47 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,2 mm/min.




Figura 6.48 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,3 mm/min.




Figura 6.49 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,4 mm/min.




Figura 6.50 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,5 mm/min.




Figura 6.51 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,6 mm/min.




Figura 6.52 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,7 mm/min.




Figura 6.53 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,8 mm/min.




Figura 6.54 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 0,9 mm/min.




Figura 6.55 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 1,0 mm/min.




Figura 6.56 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 1,25 mm/min.




Figura 6.57 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 1,5 mm/min.




Figura 6.58 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 1,75 mm/min.




Figura 6.59 – Parâmetro **DPO** para a velocidade de avanço (V_f) de 2,0 mm/min.

De acordo com a Equação 4.5, o parâmetro **DPO** é a multiplicação da potência elétrica média consumida pelo motor em um ciclo pelo desvio-padrão do sinal RMS da emissão acústica para o mesmo período. Assim, este parâmetro leva em consideração os valores de todo o ciclo. Isto é muito importante, já que a curva de cada variável de saída (**F_t**, **u**, **EA** e **DPO**) se comporta de maneira distinta para diferentes valores de velocidade de mergulho.

Em condições mais brandas de corte, quando iniciava o tempo de *spark-out*, os valores destas variáveis diminuam e rapidamente chegavam ao seu valor em vazio, pois os seus picos máximos eram pequenos. De maneira que o gráfico poderia ser ilustrado como em forma de pequenos “degraus”. Já para condições mais severas, ao iniciar o *spark-out*, os valores diminuam e formavam um gráfico parecido com uma senóide. Sendo assim, o parâmetro **DPO** leva em consideração este comportamento de cada gráfico.

Pelas Figuras 6.46 a 6.59, pôde-se observar que esta variável também aumenta com o acréscimo da velocidade de avanço. Isto fica claro pela Equação 4.5, pois o parâmetro **DPO** é diretamente proporcional à potência elétrica e ao desvio-padrão da emissão acústica. A Figura 6.60 exibe o gráfico com os valores médios dos 40 ciclos para cada velocidade de mergulho.




Figura 6.60 – Valor médio do parâmetro **DPO** para todas as velocidades de avanço.

A Figura 6.60 mostra que o parâmetro **DPO** tem um comportamento semelhante à força de corte, onde existe certa tendência dos valores a se conservarem em um nível. Este comportamento é mais nítido para esta variável.

O parâmetro **DPO** será utilizado nas RNA's para a comparação entre os seus resultados e os obtidos das redes que utilizam a emissão acústica e a força tangencial de corte.

6.1.5 Desgaste Diametral do Rebolo

O rebolo de CBN possui um desgaste muito pequeno quando comparado a um rebolo de óxido de alumínio. Isto se deve à maior dureza de seus grãos que acabam por manter a capacidade de corte do rebolo durante tempos maiores (KOHLI et al., 1995).

A Figura 6.61 apresenta os valores médios do desgaste diametral do rebolo (μm) para todas as velocidades de mergulho utilizadas.

Deve-se ressaltar que foram obtidos os valores de desgaste diametral após os 60 ciclos, ou seja, no final de cada ensaio, sendo efetuadas 6 medições em posições distintas de cada tarugo onde foi “impresso” o degrau equivalente aos respectivos desgastes. Deste modo, calculou-se a média aritmética das 6 medições e depois a média entre as 3 repetibilidades de cada grupo.




Figura 6.61 – Média do desgaste diametral para todas as velocidades de avanço.

Observando a Figura 6.61, nota-se um comportamento próximo do linear. Deste modo, o valor do desgaste diametral do rebolo tende a aumentar com a velocidade de mergulho. Isto se deu pelo aumento da tensão realizada na região de contato, ocasionando trincas no ligante e no grão do rebolo.

É importante ressaltar que na análise proposta, deve-se trabalhar com faixas de valores e não com valores absolutos. Existem problemas inerentes à máquina e ao próprio sistema de medição que refletem na diferença das medidas realizadas sob as mesmas condições de ensaio.

Especificamente no fenômeno de desgaste do rebolo, a falta de rigidez do sistema máquina-ferramenta-peça, o desgaste de guias, ou até o desgaste de mancais da máquina, pode interferir na eficiência do rebolo superabrasivo.

Assim como a força tangencial de corte e conseqüentemente a energia específica, o desgaste do rebolo pode sofrer interferência de vibrações provindas de fontes externas ao processo em si. Neste caso, como o ligante do rebolo é vitrificado, qualquer vibração adicional aos esforços inerentes do processo pode provocar a fratura do ligante e o desgaste irregular do rebolo.

Outro fator que deve ser levado em consideração é a velocidade periférica de trabalho do rebolo de CBN que é próxima de 80 m/s. Este valor é mais que o dobro da velocidade utilizada nesta pesquisa (30 m/s). Isto pode influenciar o mecanismo de desgaste do rebolo. É importante observar que a máquina foi o fator limitante da velocidade periférica do rebolo utilizada.

6.1.6 Rugosidade

Sabe-se que o acabamento superficial da peça pode afetar significativamente a resistência de componentes submetidos à fadiga. A Figura 6.62 representa os valores médios da rugosidade R_a (μm) para todas as velocidades de mergulho utilizadas.

Foram obtidos os valores de rugosidade após os 60 ciclos de 200 μm , ou seja, no final de cada ensaio, sendo efetuadas 5 medições em posições distintas de cada corpo de prova. Deste modo, calculou-se a média aritmética das 5 medições e depois a média entre as 3 repetibilidades de cada grupo de ensaios.

A rugosidade de uma peça retificada é influenciada por diversos parâmetros, tais como: tamanho do grão abrasivo; condições de dressagem; taxa de remoção de material; tempo de centelhamento, lubri-refrigeração, entre outros fatores. Neste trabalho, apenas a velocidade de mergulho foi alterada, ou seja, a taxa de remoção de material.




Figura 6.62 – Média da rugosidade para todas as velocidades de avanço.

Pela Figura 6.62, fica clara a influência da velocidade de mergulho na rugosidade final do corpo de prova. Este sofre um agravamento em seu acabamento superficial com o aumento da taxa de remoção de material. Isto se dá pelo aumento da largura de contato entre a aresta de corte e a peça.

Neste caso, os resultados possuem um comportamento muito melhor definido de linearidade ao longo do aumento da velocidade de avanço.

Além disso, pode-se observar um pequeno desvio-padrão para a maioria dos grupos de velocidade, indicando uma boa relação entre as repetibilidades das medições.

6.1.7 Circularidade

O erro de circularidade é um valor de extrema importância para o processo de retificação cilíndrica que deve estar de acordo com a tolerância especificada no projeto. Este erro está diretamente relacionado às condições de retificação adotadas e às solicitações mecânicas.

A Figura 6.63 representa uma comparação entre os valores médios do erro de circularidade (μm) para todas as velocidades de mergulho. Estes valores foram obtidos no final de cada ensaio, sendo efetuadas 3 medições em posições distintas da peça. Calculou-se

então a média aritmética das 3 medições e depois a média entre as 3 repetibilidades de cada grupo.




Figura 6.63 – Média do desvio de circularidade para todas as velocidades de avanço.

Como pode ser visto na Figura 6.63, o erro de circularidade possui um desvio-padrão muito alto para todos os grupos de ensaios. Este desvio-padrão está relacionado com a grande diferença nos valores obtidos entre as repetibilidades.

Isto ocorreu, provavelmente devido à vibração da máquina, que pode ser provocada por falta de rigidez do conjunto máquina-ferramenta-peça, desgaste de guias, rolamentos, entre outros fatores. É importante ressaltar que os valores obtidos para a circularidade são considerados baixos.

No entanto, observando apenas os valores médios, o mesmo comportamento visto para as outras variáveis estudadas, com exceção da energia específica, pode ser observado na circularidade, apesar das velocidades 0,2 e 0,4 mm/min.

Como os valores de desvio-padrão não foram utilizados como *inputs*, ou dados de entrada, das RNA's, a circularidade pôde ser aproveitada.

Cabe ressaltar que foram utilizados conjuntos de dados de características diferentes nas RNA's. Portanto, todos os dados aqui apresentados foram utilizados.

6.2 RESULTADOS DAS REDES NEURAIS ARTIFICIAIS

Os resultados das redes neurais artificiais estão concentrados em três investigações diferentes:

- ❖ A determinação da quantidade de neurônios da camada intermediária para cada RNA;
- ❖ A verificação do grupo de entradas que melhor representa o processo de retificação para cada base de dados; e
- ❖ A definição da RNA que obteve os resultados mais precisos na predição das variáveis propostas.

6.2.1 Escolha do Número de Neurônios da Camada Oculta

Neste tópico são apresentados os resultados dos testes com as diversas configurações de camada oculta das redes neurais. Portanto, será definido o número de neurônios da camada intermediária para todas as RNA's testadas.

Como já foi mencionado no sub-item 5.7.4, cada RNA foi testada com um número de neurônios da camada oculta variando de 4 a 12. Portanto, cada RNA possui 9 configurações diferentes de neurônios.

6.2.1.1 RNA's da base de dados A

De acordo com a classificação adotada, as RNA's desta base de dados foram denominadas:

- ❖ **MLP – A_I**;
- ❖ **MLP – A_{II}**; e
- ❖ **MLP – A_{III}**.

As Figuras 6.64 a 6.72 exibem a regressão linear (apresentado como *best linear fit*) da média dos resultados obtidos para as 10 simulações realizadas para a RNA **MLP – A_I**, onde as variáveis de entrada da rede são: o parâmetro **DPO**, o desgaste diametral do rebolo, a velocidade de avanço e a energia específica de retificação. Como pode ser observado, os números são apresentados no formato inglês, pois estes gráficos são gerados pelo Matlab 6.5 que possui como idioma padrão o inglês. Deve-se considerar portanto, a vírgula ao invés do ponto.

É importante lembrar que nesta base de dados (**A**), os dados para a validação são referentes apenas a três velocidades, sendo estas: 0,3; 0,7; e 1,25 mm/min.




Figura 6.64 – Regressão linear da média das saídas para a **MLP – A_I – 4x4x2**.




Figura 6.65 – Regressão linear da média das saídas para a **MLP – A_I – 4x5x2**.




Figura 6.66 – Regressão linear da média das saídas para a **MLP – A_I – 4x6x2**.




Figura 6.67 – Regressão linear da média das saídas para a **MLP – A_I – 4x7x2**.




Figura 6.68 – Regressão linear da média das saídas para a **MLP – A_I – 4x8x2**.




Figura 6.69 – Regressão linear da média das saídas para a **MLP – A_I – 4x9x2**.




Figura 6.70 – Regressão linear da média das saídas para a MLP – A_I – 4x10x2.




Figura 6.71 – Regressão linear da média das saídas para a MLP – A_I – 4x11x2.




Figura 6.72 – Regressão linear da média das saídas para a MLP – A_I – 4x12x2.

Nas Figuras 6.64 a 6.72, estão representados as saídas das RNA's. Para esta base de dados, a validação foi realizada com três conjuntos de dados, portanto estes valores (predição e valores reais) estão representados nos gráficos, onde, as regressões lineares à direita são referentes aos valores de circularidade e à esquerda aos de rugosidade.

Pode-se notar dentro de cada gráfico o valor do coeficiente de correlação linear (**R**). Este coeficiente é uma maneira de medir o grau de associação linear entre a saída da rede neural e os valores medidos. Quanto mais próximo de 1,0 for o coeficiente, melhor é a predição da rede. Deste modo, as retas pontilhadas dos gráficos representam os valores reais (medidos) e as retas contínuas os valores da predição da RNA.

Outra informação encontrada nos gráficos, é o coeficiente angular e linear da reta de regressão. Para o coeficiente angular, valores próximos de 1,0 são os ideais, já para o coeficiente linear, quanto mais próximo de 0 (zero) melhor é a associação entre os resultados obtidos das redes e os valores reais.

Na verificação destes valores, fica evidente a maior precisão dos resultados para a rugosidade. Isto acontece para todas as configurações da camada oculta. Esta característica pode ser observada nos coeficientes lineares, angulares e conseqüentemente nos coeficientes de correlação linear.

Este fato é explicado pelos dados de circularidade e rugosidade utilizados nas RNA's. Os valores de rugosidade (Figura 6.62) possuem uma tendência muito mais clara do que os de circularidade (Figura 6.63).

Isto também explica o comportamento das retas de regressão linear da circularidade. Estas estão visivelmente mais deslocadas em relação a reta referente aos valores reais (retas pontilhadas). Esta diferença é maior no início da reta (primeira e segunda velocidades de avanço usadas na validação) e depois converge até bem próximo da reta pontilhada. Isto indica que os resultados, ou saídas das RNA's foram melhores e mais precisas para o último conjunto de dados (última velocidade de avanço).

Os valores da circularidade utilizados no treinamento da RNA podem ter prejudicado e conseqüentemente aumentado o valor dos coeficientes de correlação.

Esta afirmação pode ser comprovada pela Figura 6.63. Nesta figura pode-se perceber que o valor para a velocidade 0,3 mm/min (usado na validação e construção dos gráficos de regressão linear) está entre dois valores (referentes às velocidades 0,2 e 0,4 mm/min) que fogem à tendência percebida para o resto das velocidades. Portanto, a rede que foi treinada para estes valores destoantes, deve responder na simulação um valor de circularidade próximo daqueles. Isso faz com que o erro entre a resposta e o valor real seja um pouco maior.

A Tabela 6.1 a seguir exibe os erros de predição para cada conjunto de dados, ou velocidade de avanço. Os valores de erros deste trabalho estão em porcentagem. As variáveis circularidade e rugosidade são representadas pelos seus símbolos: **O** e **R_a**, respectivamente.

Tabela 6.1 – Erros (%) dos valores médios das saídas das RNA's **A_I**.

	V_f = 0,3 mm/min		V_f = 0,7 mm/min		V_f = 1,25 mm/min	
	Erro O	Erro R_a	Erro O	Erro R_a	Erro O	Erro R_a
A _I – 4x4x2	9,2349	1,8520	11,1938	1,7552	0,7123	1,4948
A _I – 4x5x2	7,4788	1,7871	10,6426	0,6448	0,8481	0,8454
A _I – 4x6x2	8,7345	1,6329	16,3844	2,2612	0,0472	0,2296
A _I – 4x7x2	8,1951	0,6881	14,4727	0,9735	0,2768	1,4628
A _I – 4x8x2	8,7497	1,6514	12,7283	2,0993	0,2073	0,9486
A _I – 4x9x2	9,8398	1,2746	15,1446	1,5678	0,5632	1,3373
A _I – 4x10x2	8,4085	2,2597	11,9741	0,3594	0,6355	1,0351
A _I – 4x11x2	8,7981	1,1438	7,64240	2,1013	0,6693	1,3442
A _I – 4x12x2	8,8417	1,0612	14,3069	3,7189	0,0110	1,0902

A Tabela 6.2 apresenta a média dos erros da Tabela 6.1 e os valores dos coeficientes de correlação (**R**) retirados dos gráficos. Esta tabela serviu como objeto de tomada de decisão, pois o número de neurônios da camada interna foi determinado pela média total dos erros percentuais entre a circularidade e rugosidade.

Tabela 6.2 – Média dos erros (%) e valores do coeficiente de correlação (**R**) das RNA's **A_I**.

	Média dos erros O	Média dos erros R_a	Média total dos erros	R (O)	R (R_a)
A _I – 4x4x2	7,0470	1,7006	4,37380	0,960	0,999
A _I – 4x5x2	6,3232	1,0924	3,70780	0,960	1,0
A _I – 4x6x2	8,3887	1,3745	4,88160	0,900	0,998
A _I – 4x7x2	7,6482	1,0415	4,34485	0,922	1,0
A _I – 4x8x2	7,2284	1,5664	4,39740	0,946	0,999
A _I – 4x9x2	8,5158	1,3932	4,95450	0,912	1,0
A _I – 4x10x2	7,0060	1,2181	4,11205	0,950	1,0
A _I – 4x11x2	5,7033	1,5298	3,61655	0,989	0,999
A _I – 4x12x2	7,7199	1,9568	4,83835	0,929	0,997

A Tabela 6.1 mostra valores próximos do real para a rugosidade e valores menos precisos para a circularidade. Por esta tabela, é possível entender melhor o comentário feito à respeito da distância das retas nos gráficos de regressão, já que os valores do erro para a circularidade são bem maiores para as velocidades 0,3 e 0,7 mm/min do que para a última (1,25 mm/min).

Pela Tabela 6.2, pode-se notar que para a RNA A_I , o menor erro na predição da circularidade e rugosidade é gerado pela rede de 11 neurônios na camada intermediária. Portanto, esta RNA será representada por **MLP – A_I – 4x11x2**.

Os próximos gráficos são referentes às regressões lineares da média das saídas das RNA's **MLP – A_{II}** e são exibidas nas Figuras 6.73 a 6.81.




Figura 6.73 – Regressão linear da média das saídas para a **MLP – A_{II} – 5x4x2**.




Figura 6.74 – Regressão linear da média das saídas para a **MLP – A_{II} – 5x5x2**.




Figura 6.75 – Regressão linear da média das saídas para a MLP – A_{II} – 5x6x2.




Figura 6.76 – Regressão linear da média das saídas para a MLP – A_{II} – 5x7x2.




Figura 6.77 – Regressão linear da média das saídas para a MLP – A_{II} – 5x8x2.




Figura 6.78 – Regressão linear da média das saídas para a **MLP – A_{II} – 5x9x2**.




Figura 6.79 – Regressão linear da média das saídas para a **MLP – A_{II} – 5x10x2**.




Figura 6.80 – Regressão linear da média das saídas para a **MLP – A_{II} – 5x11x2**.




Figura 6.81 – Regressão linear da média das saídas para a **MLP – A_{II} – 5x12x2**.

Estas redes possuem como entrada: a força tangencial de corte; a emissão acústica, a velocidade de avanço, a energia específica e o desgaste diametral do rebolo.

Pelas Figuras 6.73 a 6.81, pode-se perceber novamente a maior precisão na predição para os valores de rugosidade, já que as duas retas estão praticamente sobrepostas. Isto se reflete nos valores do coeficiente de correlação linear, que em sua grande maioria, possuem 1,0 como valor, indicando uma associação ideal. Já na predição da circularidade, as retas da regressão apresentam o mesmo aspecto das RNA's A_I , distantes da reta ideal. Apresentam também uma maior distância para os valores de 0,3 e 0,7 mm/min, gerando um maior erro.

A Tabela 6.3 a seguir mostra os valores dos erros médios das saídas destas RNA's.

Tabela 6.3 – Erros (%) dos valores médios das saídas das RNA's A_{II} .

	$V_f = 0,3 \text{ mm/min}$		$V_f = 0,7 \text{ mm/min}$		$V_f = 1,25 \text{ mm/min}$	
	Erro O	Erro R_a	Erro O	Erro R_a	Erro O	Erro R_a
$A_{II} - 5x4x2$	2,1839	0,058	15,1618	2,2673	0,8996	0,5513
$A_{II} - 5x5x2$	3,8079	1,1626	12,8209	1,1358	1,0932	1,6474
$A_{II} - 5x6x2$	1,5675	0,2301	9,7134	0,5961	3,2410	1,0617
$A_{II} - 5x7x2$	1,5313	0,0612	7,3577	2,6648	1,0996	0,9483
$A_{II} - 5x8x2$	2,1033	0,3890	6,6894	0,9159	0,8749	1,1333
$A_{II} - 5x9x2$	2,2963	0,0999	7,7846	0,7817	3,5531	0,4170
$A_{II} - 5x10x2$	2,9126	0,4178	10,7828	1,4362	1,3207	1,3483
$A_{II} - 5x11x2$	2,4922	0,5144	9,7005	0,4938	1,8490	1,2712
$A_{II} - 5x12x2$	2,3325	0,5042	9,4127	0,1482	1,1642	0,4937

Observando a Tabela 6.3, fica claro a menor precisão na predição dos valores de circularidade. Para a circularidade, a pior predição para os valores de velocidade de avanço igual a 0,3 e 0,7 mm/min também se repete nas RNA's A_I .

A Tabela 6.4 apresenta a média dos erros da Tabela 6.3 e os valores dos coeficientes de correlação (R) retirados dos gráficos.

Tabela 6.4 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's A_{II} .

	Média dos erros O	Média dos erros R_a	Média total dos erros	R (O)	R (R_a)
$A_{II} - 5 \times 4 \times 2$	6,0818	0,9589	3,50350	0,891	0,999
$A_{II} - 5 \times 5 \times 2$	5,9073	1,3153	3,61130	0,922	1,0
$A_{II} - 5 \times 6 \times 2$	4,8406	0,6293	2,73495	0,930	1,0
$A_{II} - 5 \times 7 \times 2$	3,3295	1,2248	2,27715	0,972	0,998
$A_{II} - 5 \times 8 \times 2$	3,2225	0,8128	2,01765	0,979	1,0
$A_{II} - 5 \times 9 \times 2$	4,5447	0,4329	2,48880	0,952	1,0
$A_{II} - 5 \times 10 \times 2$	5,0054	1,0675	3,03645	0,941	1,0
$A_{II} - 5 \times 11 \times 2$	4,6805	0,7598	2,72015	0,947	1,0
$A_{II} - 5 \times 12 \times 2$	4,3031	0,3821	2,34260	0,955	1,0

Analisando-se a Tabela 6.4, tem-se que a rede neural **MLP – $A_{II} - 5 \times 8 \times 2$** , com 8 neurônios na camada oculta obtém a melhor predição. Esta configuração possui o valor do coeficiente de correlação referente à circularidade mais próximo do ideal (1,0). Como na RNA – A_{II} , a média dos erros na predição da circularidade foi decisiva para a escolha do número de neurônios da camada intermediária.

Posteriormente será definida a quantidade de neurônios do último grupo de entradas para a base de dados **A**. As entradas citadas são: o parâmetro **DPO**; a força tangencial de corte; a emissão acústica; o desgaste diametral do rebolo; a velocidade de avanço e a energia específica de retificação.

Portanto, as Figuras 6.82 a 6.90 exibem a regressão linear da média das saídas obtidas para as 10 simulações realizadas para a RNA **MLP – A_{III}** .




Figura 6.82 – Regressão linear da média das saídas para a MLP – A_{III} – 6x4x2.




Figura 6.83 – Regressão linear da média das saídas para a MLP – A_{III} – 6x5x2.




Figura 6.84 – Regressão linear da média das saídas para a MLP – A_{III} – 6x6x2.




Figura 6.85 – Regressão linear da média das saídas para a MLP – A_{III} – 6x7x2.




Figura 6.86 – Regressão linear da média das saídas para a MLP – A_{III} – 6x8x2.




Figura 6.87 – Regressão linear da média das saídas para a MLP – A_{III} – 6x9x2.




Figura 6.88 – Regressão linear da média das saídas para a MLP – A_{III} – 6x10x2.




Figura 6.89 – Regressão linear da média das saídas para a MLP – A_{III} – 6x11x2.




Figura 6.90 – Regressão linear da média das saídas para a MLP – A_{III} – 6x12x2.

As mesmas observações anteriores feitas às RNA's A_I e A_{II} se repetem para as RNA's A_{III} . Nestas, a predição para os valores de circularidade são prejudicados pelos dados de treinamento. Já a rugosidade possui todos os valores do coeficiente de regressão iguais ou muito próximos de 1,0. A Tabela 6.5 exibe os erros da predição de O e R_a para estas RNA's.

Tabela 6.5 – Erros (%) dos valores médios das saídas das RNA's A_{III} .

	$V_f = 0,3 \text{ mm/min}$		$V_f = 0,7 \text{ mm/min}$		$V_f = 1,25 \text{ mm/min}$	
	Erro O	Erro R_a	Erro O	Erro R_a	Erro O	Erro R_a
$A_{III} - 6x4x2$	2,1052	0,9094	13,1735	2,1892	1,5146	1,7374
$A_{III} - 6x5x2$	2,4352	0,1105	11,9994	0,0562	1,0247	1,4790
$A_{III} - 6x6x2$	1,6725	0,1004	7,0064	3,0259	0,5157	1,1783
$A_{III} - 6x7x2$	1,2931	0,4607	10,4193	1,7801	0,4189	0,3649
$A_{III} - 6x8x2$	2,2104	0,2936	9,9018	0,0979	0,6327	0,0224
$A_{III} - 6x9x2$	1,5607	0,0863	7,8149	0,7630	0,1738	0,6217
$A_{III} - 6x10x2$	2,0480	0,0942	10,4493	0,5985	2,0154	0,9952
$A_{III} - 6x11x2$	2,7391	0,2326	7,3282	0,6875	0,9687	1,0965
$A_{III} - 6x12x2$	3,0915	0,7306	9,7085	0,4705	0,6471	0,1798

A Tabela 6.5 também apresenta as mesmas características das outras já discutidas. Fica clara a pior predição da circularidade para as velocidades 0,3 e 0,7 mm/min. A Tabela 6.6 apresenta a média dos erros e os valores dos coeficientes de correlação (R).

Tabela 6.6 – Média dos erros (%) e valores do coeficiente de correlação (R) das RNA's A_{III} .

	Média dos erros O	Média dos erros R_a	Média total dos erros	R (O)	R (R_a)
$A_{III} - 6x4x2$	5,5978	1,6120	3,60490	0,909	0,999
$A_{III} - 6x5x2$	5,1531	0,5485	2,85080	0,929	1,0
$A_{III} - 6x6x2$	3,0649	1,4349	2,24990	0,978	0,997
$A_{III} - 6x7x2$	4,0438	0,8686	2,45620	0,949	0,999
$A_{III} - 6x8x2$	4,2483	0,1380	2,19315	0,955	1,0
$A_{III} - 6x9x2$	3,1831	0,4903	1,83670	0,975	1,0
$A_{III} - 6x10x2$	4,8376	0,5626	2,70010	0,936	1,0
$A_{III} - 6x11x2$	3,6786	0,6722	2,17540	0,976	1,0
$A_{III} - 6x12x2$	4,4824	0,4603	2,47135	0,959	1,0

Observando-se a Tabela 6.6, tem-se que a configuração 6x9x2 possui a menor média total dos erros de circularidade e rugosidade. Apesar disso, não se repetiu nestas RNA's, o fato de que a configuração com menor média total dos erros também possuía o coeficiente de correlação mais próximo de 1,0, em se tratando de circularidade. Neste caso, as configurações com 6 e 11 neurônios na camada interna possuem coeficientes mais próximos de 1,0 do que a 6x9x2, mesmo esta possuindo uma menor média total, o que difere dos casos anteriores.

Com o número de neurônios da camada oculta das três RNA's de base de dados A definidas, são apresentados agora os resultados restantes para as RNA's de base de dados B.

6.2.1.2 RNA's da base de dados B

As RNA's desta base de dados foram denominadas:

- ❖ **MLP – B_I**;
- ❖ **MLP – B_{II}**; e
- ❖ **MLP – B_{III}**.

As Figuras 6.91 a 6.99 exibem a regressão linear da média dos resultados obtidos para as 10 simulações realizadas para a RNA **MLP – B_I**, onde as variáveis de entrada da rede são: o parâmetro **DPO**, o desgaste diametral do rebolo, a velocidade de avanço e a energia específica de retificação.

Nesta base de dados (**B**), foram utilizados 420 conjuntos para o treinamento e 140 para a validação.




Figura 6.91 – Regressão linear da média das saídas para a **MLP – B_I – 4x4x2**.




Figura 6.92 – Regressão linear da média das saídas para a **MLP – B_I – 4x5x2**.




Figura 6.93 – Regressão linear da média das saídas para a **MLP – B_I – 4x6x2**.




Figura 6.94 – Regressão linear da média das saídas para a **MLP – B_I – 4x7x2**.




Figura 6.95 – Regressão linear da média das saídas para a **MLP – B_I – 4x8x2**.




Figura 6.96 – Regressão linear da média das saídas para a **MLP – B_I – 4x9x2**.




Figura 6.97 – Regressão linear da média das saídas para a **MLP – B_I – 4x10x2**.




Figura 6.98 – Regressão linear da média das saídas para a **MLP – B₁ – 4x11x2**.




Figura 6.99 – Regressão linear da média das saídas para a **MLP – B₁ – 4x12x2**.

Primeiramente, pode-se perceber que a quantidade de pontos é muito maior que nos gráficos da base de dados **A**, devido à diferença do número de conjuntos utilizados na validação.

Observando os gráficos atentamente, nota-se a mesma característica de todos os gráficos referentes à base de dados **A**. Ou seja, as retas de regressão linear para os resultados de circularidade possuem um deslocamento em relação à reta de regressão dos valores reais. Isto é absolutamente normal, pois os valores de circularidade são iguais para as duas bases de dados, o que muda é a quantidade destes dados, já que a base de dados **B** repete todos os valores para cada um dos 40 ciclos.

Analisando as retas da regressão linear de circularidade, é possível perceber que este deslocamento citado acima, ou seja, a distância entre a reta de regressão linear das saídas da rede e os valores reais é maior para as menores velocidades.

De acordo com o gráfico da Figura 6.63, no qual os valores de circularidade utilizados nas RNA's são expostos em um gráfico de coluna, nota-se que os valores para as velocidades mais altas possuem uma tendência mais definida do que os das velocidades de mergulho mais baixas. Isto explica porque as retas de regressão linear das saídas da rede estão mais próximas da reta ideal para as maiores velocidades.

Caso fosse apresentado aqui os valores dos erros da predição referentes à cada conjunto de ensaios, como nos resultados da base de dados **A**, seria observado que estes erros são menores para as velocidades mais altas.

No entanto, pelo fato de ter sido utilizado na validação 140 conjuntos de dados (10 conjuntos para cada velocidade), os resultados desta base de dados são apresentados em uma única tabela contendo a média dos erros para a circularidade e rugosidade.

Além disso, estas tabelas também apresentam a média total e os valores dos coeficientes de correlação (**R**) de circularidade e rugosidade retirados dos gráficos.

A Tabela 6.7 a seguir mostra estes valores referentes ao primeiro grupo de variáveis de entrada.

Tabela 6.7 – Média dos erros (%) e valores do coeficiente de correlação (**R**) das RNA's **B_I**.

	Média dos erros O	Média dos erros R_a	Média total dos erros	R (O)	R (R_a)
B _I – 4x4x2	4,8833	3,5982	4,24075	0,921	0,994
B _I – 4x5x2	4,6971	2,5069	3,60200	0,924	0,997
B _I – 4x6x2	4,6470	2,4691	3,55805	0,930	0,996
B _I – 4x7x2	4,6801	2,2998	3,48995	0,929	0,997
B _I – 4x8x2	4,3177	2,0552	3,18645	0,934	0,997
B _I – 4x9x2	4,9261	2,0222	3,47415	0,934	0,997
B _I – 4x10x2	4,8981	2,3392	3,61865	0,933	0,997
B _I – 4x11x2	4,1805	1,9405	3,06050	0,934	0,998
B _I – 4x12x2	4,3717	2,1854	3,27855	0,936	0,997

Segundo a Tabela 6.7, a configuração de rede com 11 neurônios na camada interna é a que possui uma melhor precisão na predição da circularidade e rugosidade.

O valor do coeficiente de correlação da rugosidade é o mais próximo do 1,0 nesta configuração, o que não acontece para a variável circularidade, que tem a configuração 4x12x2 com o valor mais próximo de 1,0. Apesar disso, esta RNA com 12 neurônios na

camada intermediária possui uma média de erro de circularidade maior do que a configuração 4x11x2. Isto ratifica a escolha da rede neural com 11 neurônios na camada oculta.

Em seguida são apresentados os gráficos de regressão linear referente às redes neurais **MLP – B_{II}** (Figuras 6.100 a 6.108). Estas redes possuem como variáveis de entrada: a força tangencial de corte; a emissão acústica, a velocidade de avanço, o desgaste diametral do rebolo e energia específica de retificação.




Figura 6.100 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x4x2**.




Figura 6.101 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x5x2**.




Figura 6.102 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x6x2**.




Figura 6.103 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x7x2**.




Figura 6.104 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x8x2**.




Figura 6.105 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x9x2**.




Figura 6.106 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x10x2**.




Figura 6.107 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x11x2**.




Figura 6.108 – Regressão linear da média das saídas para a **MLP – B_{II} – 5x12x2**.

Segundo os gráficos das Figuras 6.100 a 6.108, as mesmas observações feitas para as RNA's já vistas até aqui são mantidas. Assim, a reta de regressão linear para a circularidade possui uma pior associação com os valores reais quando comparada com a rugosidade. Também se observam neste caso os piores resultados da predição da circularidade para as velocidades mais baixas.

O coeficiente de correlação para a rugosidade novamente possui valores bem próximos de 1,0, indicando uma boa precisão na predição.

A tabela abaixo indica as médias do erro na predição para a circularidade e rugosidade, assim como a média total destes erros e os valores do coeficiente de correlação para as respectivas variáveis.

Tabela 6.8 – Média dos erros (%) e valores do coeficiente de correlação (**R**) das RNA's **B_{II}**.

	Média dos erros O	Média dos erros R _a	Média total dos erros	R (O)	R (R _a)
B _{II} – 5x4x2	4,5302	3,2305	3,88035	0,929	0,993
B _{II} – 5x5x2	4,0568	2,4483	3,25255	0,943	0,996
B _{II} – 5x6x2	3,7330	2,3520	3,04250	0,946	0,996
B _{II} – 5x7x2	3,6345	2,2043	2,91940	0,946	0,997
B _{II} – 5x8x2	3,7135	1,9817	2,84760	0,944	0,997
B _{II} – 5x9x2	3,5993	1,7486	2,67395	0,951	0,998
B _{II} – 5x10x2	3,6151	1,6330	2,62405	0,952	0,998
B _{II} – 5x11x2	3,8260	1,8125	2,81925	0,955	0,997
B _{II} – 5x12x2	3,2871	1,5950	2,44105	0,952	0,998

A Tabela 6.8 exibe a configuração 5x12x2 como a melhor opção para a quantidade de neurônios presentes na camada oculta da RNA. Este arranjo apresenta o menor erro na predição tanto da circularidade quanto da rugosidade.

A seguir, para definir esta fase da análise referente ao número de neurônios da camada intermediária, são apresentados os gráficos do último grupo de dados relativo à esta base de dados. Sendo este formado pela força tangencial de corte, emissão acústica, parâmetro **DPO**, velocidade de avanço, desgaste diametral do rebolo e energia específica de retificação.

Estes gráficos estão representados nas Figuras 6.109 a 6.117, que exibem a regressão linear da média das saídas obtidas para as 10 simulações realizadas para a RNA **MLP – B_{III}**.




Figura 6.109 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x4x2**.




Figura 6.110 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x5x2**.




Figura 6.111 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x6x2**.




Figura 6.112 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x7x2**.




Figura 6.113 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x8x2**.




Figura 6.114 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x9x2**.




Figura 6.115 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x10x2**.




Figura 6.116 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x11x2**.




Figura 6.117 – Regressão linear da média das saídas para a **MLP – B_{III} – 6x12x2**.

As observações realizadas para os gráficos de regressão linear dos resultados de circularidade e rugosidade se repetem novamente. A predição da rugosidade se mostrou mais precisa do que a circularidade. Os seus valores de coeficiente de regressão linear são bem próximos de 1,0, indicando uma associação bem próxima do ideal. A circularidade por sua vez, possui coeficientes de correlação linear menores e retas ligeiramente deslocadas das retas ideais, indicando uma pior predição.

A Tabela 6.9 exibe os valores destes erros, assim como o coeficiente de correlação linear para as configurações acima.

Tabela 6.9 – Média dos erros (%) e valores do coeficiente de correlação (**R**) das RNA's **B_{III}**.

	Média dos erros O	Média dos erros R _a	Média total dos erros	R (O)	R (R _a)
B _{III} – 6x4x2	4,3641	2,6427	3,5034	0,942	0,995
B _{III} – 6x5x2	4,1085	2,3743	3,2414	0,947	0,996
B _{III} – 6x6x2	4,4610	2,0392	3,2501	0,944	0,997
B _{III} – 6x7x2	4,2515	1,9807	3,1161	0,946	0,997
B _{III} – 6x8x2	3,9427	1,9518	2,94725	0,948	0,997
B _{III} – 6x9x2	4,1946	1,5615	2,87805	0,948	0,998
B _{III} – 6x10x2	3,7947	1,6522	2,72345	0,953	0,998
B _{III} – 6x11x2	4,0055	1,7280	2,86675	0,950	0,998
B _{III} – 6x12x2	4,0098	1,8308	2,9203	0,951	0,998

Pela Tabela 6.9, o arranjo que apresenta o menor erro médio total é o 6x10x2 que também apresenta os maiores valores do coeficiente de correlação linear para ambas as variáveis.

Portanto, as configurações finais obtidas das redes neurais artificiais foram:

- ❖ **MLP – A_I – 4x11x2;**
- ❖ **MLP – A_{II} – 5x8x2;**
- ❖ **MLP – A_{III} – 6x9x2;**
- ❖ **MLP – B_I – 4x11x2;**
- ❖ **MLP – B_{II} – 5x12x2; e**
- ❖ **MLP – B_{III} – 6x10x2.**

6.2.2 Comparação Entre as RNA's

Para a comparação final entre as RNA's selecionadas no item 6.1.1, foram executados 10 treinamentos para cada configuração. Todos os dados disponíveis em cada base de dados foram utilizados.

Após cada treinamento, foi realizada uma simulação utilizando novamente todos os dados possíveis de cada base de dados. Assim, foi escolhido o melhor resultado dos 10 treinamentos e simulações para a comparação final.

Primeiramente, são exibidos os gráficos de regressão linear para as redes neurais da base de dados A. Estes gráficos são representados nas Figuras 6.118 a 6.120 a seguir.




Figura 6.118 – Regressão linear dos resultados da RNA **MLP – A_I – 4x11x2**.




Figura 6.119 – Regressão linear dos resultados da RNA **MLP – A_{II} – 5x8x2**.




Figura 6.120 – Regressão linear dos resultados da RNA **MLP – A_{III} – 6x9x2**.

Para esta base de dados, as Figuras 6.118 a 6.120 apresentam valores dos coeficientes de correlação tanto para a rugosidade quanto para a circularidade muito próximos de 1,0. Indicando uma boa predição das redes neurais, ou seja, resultados muito próximos dos reais.

Para o primeiro grupo de entradas, onde o parâmetro **DPO** é a variável diferente e a velocidade de corte, o desgaste diametral do rebolo e a energia específica as variáveis

comuns, o coeficiente de correlação para a circularidade, apesar de muito próximo de 1,0, é o valor mais baixo das três redes neurais.

Isto indica que, ao contrário do que se esperava, o parâmetro **DPO** não foi capaz de suprir as entradas de força tangencial de corte e emissão acústica. Neste sentido, esperava-se que esta rede neural (grupo I) obtivesse resultado igual ou até mais preciso do que a rede referente às entradas de força tangencial de corte e emissão acústica (grupo II), o que não ocorreu.

No entanto, pôde-se verificar que quando o parâmetro **DPO** foi adicionado à entrada da RNA contendo a força tangencial de corte e a emissão acústica (**MLP – A_{III} – 6x9x2** na Figura 6.120), a predição da rede sofre uma ligeira melhora.

Isto indica que este parâmetro (**DPO**) não substitui de forma idêntica a força tangencial de corte e a emissão acústica. No entanto, este parâmetro somado à força e emissão acústica como entradas de uma rede neural, é benéfica e não prejudica de forma alguma a predição da rede.

Fica claro observar aqui que estas observações são válidas para redes neurais que se utilizam de uma base de dados pequena, como a base de dados **A** utilizada.

Os gráficos das regressões lineares para as redes neurais escolhidas da base de dados **B** são exibidos a seguir (Figuras 6.121 a 6.123).




Figura 6.121 – Regressão linear dos resultados da RNA **MLP – B_I – 4x11x2**.




Figura 6.122 – Regressão linear dos resultados da RNA **MLP – B_{II} – 5x12x2**.




Figura 6.123 – Regressão linear dos resultados da RNA **MLP – B_{III} – 6x10x2**.

De acordo com as Figuras 6.121 a 6.123, nota-se uma sensível melhora para a predição da rugosidade quando existe a adição de entrada na rede e uma melhora considerável para a estimativa da circularidade. Ou seja, quanto maior for a quantidade de entradas, melhor é a predição da rede. Esta afirmação é válida para o universo das variáveis testadas.

Neste caso, como a base de dados **B** é muito maior do que a base de dados **A**, é normal que os resultados desta sejam menos precisos.

No entanto, estas redes neurais são mais completas pela própria base de dados. Já que foram treinadas com todos os 40 ciclos de cada velocidade de avanço. Portanto, estas redes têm um poder de generalização maior que as redes da base de dados **A**, ou seja, conseguem extrair mais “conhecimento” do processo que as redes referentes à base de dados **A**.

Não é o intuito deste trabalho realizar uma comparação entre as duas bases de dados, mas sim, verificar a possibilidade do uso de ambas.

A Tabela 6.10 a seguir mostra os resultados das médias dos erros obtidos das simulações com todos os dados disponíveis.

Tabela 6.10 – Média dos erros (%) dos resultados para as configurações finais das RNA's.

RNA's	Média dos erros O	Média dos erros R_a	Média total dos erros
MLP – A _I – 4x11x2	1,7709	1,0100	1,39045
MLP – A _{II} – 5x8x2	0,8152	1,0166	0,91590
MLP – A _{III} – 6x9x2	0,8976	0,2707	0,58415
MLP – B _I – 4x11x2	3,7350	2,5774	3,15620
MLP – B _{II} – 5x12x2	3,2809	2,1392	2,71005
MLP – B _{III} – 6x10x2	3,2769	1,9286	2,60275

A Tabela 6.10 resume os comentários feitos anteriormente. A predição melhora com o acréscimo de dados de entrada. Esta melhora é em maior proporção para as redes de base de dados **A**.

7 CONCLUSÕES

Com base nos resultados obtidos no capítulo 6 deste trabalho e na revisão bibliográfica feita a respeito deste assunto, conclui-se que:

- ❖ Os estudos referentes à predição de erros geométricos e dimensionais, assim como de acabamento superficial de peças retificadas, não são suficientes e apesar da ampliação das pesquisas relacionadas ao processo de retificação, não existe uma pesquisa direcionada a se obter um sistema confiável na predição destes parâmetros, de forma a diminuir a necessidade de medições;
- ❖ Pelos resultados obtidos de circularidade, verificou-se a necessidade de uma variável de entrada da RNA que represente a rigidez dinâmica do sistema máquina-ferramenta-peça;
- ❖ Os resultados da predição de rugosidade foram muito próximos dos valores reais, indicando uma boa representação das variáveis de entrada para os fenômenos físicos ligados à rugosidade.
- ❖ O parâmetro **DPO** não foi capaz de gerar menores erros na predição quando este substituía as variáveis: força tangencial de corte e emissão acústica;
- ❖ Não é possível a comparação dos resultados entre as duas bases de dados, pois a base de dados **B**, apesar de resultar em predições menos precisas que os resultados da base de dados **A**, representa mais fielmente os fenômenos físicos do processo de retificação; e
- ❖ Ainda acerca da base de dados **B**, esta se mostrou confiável o suficiente para ser utilizada no treinamento de uma RNA de controle *online* do processo baseado na predição dos parâmetros finais da peça retificada.

8 SUGESTÕES PARA TRABALHOS FUTUROS

Com base nos estudos realizados e nas conclusões alcançadas, as sugestões são:

- ❖ A adição de um acelerômetro como uma alternativa de se obter uma variável que represente a rigidez do sistema. Existem inúmeras possibilidades de se tratar este sinal e extrair o máximo de características possíveis. Uma é utilizar o valor RMS como também o valor da Transformada Rápida de Fourier;
- ❖ A utilização de outros parâmetros derivados da emissão acústica como dados de entrada da rede neural e a verificação de sua contribuição à predição;
- ❖ A adoção de um sistema que consiga medir de modo preciso a velocidade de avanço do rebolo. Como exemplo: a utilização de réguas ópticas; e
- ❖ A montagem de um sistema inteligente de arquitetura aberta utilizando as redes neurais artificiais no controle do processo com a predição dos parâmetros finais da peça.

REFERÊNCIAS BIBLIOGRÁFICAS

AGOSTINHO, O. L.; RODRIGUES, A. C. S.; LIRANI, J. **Tolerância, ajuste, desvios e análise de dimensões**. São Paulo: Edgard Blücher, 1981.

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.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L. **Redes neurais artificiais com aplicações em controles e em sistemas especialistas**. Florianópolis, Bookstore, p.3-5, 2000.

BAUCHSPIESS, A. **Introdução aos Sistemas Inteligentes**. Disponível em: <<http://www.ene.unb.br/~adolfo/ISI/isi.pdf>>. Acesso em: janeiro, 2004.

BIFANO, T. G. e YI, Y. **Acoustic Emission as an Indicator of Material-Removal Regime in Glass Micro-Machining**. Precision Engineering, Vol 4, No 4, pp. 219-227, October 1992.

BIFFI, M. **Desenvolvimento do processo de retificação com alta velocidade em sede de válvulas de motores à combustão interna usando rebolo de CBN vitrificado**. Dissertação (Mestrado em Engenharia Mecânica) – Escola de Engenharia de São Carlos – Universidade de São Paulo, São Carlos, 2003.

CAMPBELL, J.D. **Optimized Coolant Application**. Technical Paper, MR95-211, Society of Manufacturing Engineers, 1995.

CARVALHO, A. P. L. F. **Redes neurais artificiais**. Disponível em: <<http://www.icmc.usp.br/~andre/research/neural/>>. Acesso em: fevereiro, 2004.

DINIZ, A. E.; CUPINI, N. L.; VILELLA, R. C. **Monitoramento do processo de usinagem por emissão acústica**. XI Congresso Brasileiro de Engenharia Mecânica, São Paulo, dezembro de 1991.

DORNFELD, D. e CAI, H. G. **An investigation of grinding and wheel loading using acoustic emission**. ASME, v.106, p.28-33, 1984.

FUSSE, R. Y.; BIANCHI, E. C.; FRANÇA, T. V.; CATAI, R. E.; SILVA, L. R. e AGUIAR, P. R. **Erros geométricos na retificação do aço SAE HVN-3**. Revista Máquinas & Metais, Aranda Editora, ano XL, nº464, pp. 150-163, setembro, 2004.

HAHN, R. S. e LINDSAY, R. P. **The wheel removal parameter**. Principles of Grinding. Machinery: 33-39, part III, 1971.

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

HITCHINER, M. P. **Technological advances in creep feed grinding of superalloys with CBN**. In: 3rd International Machining and Grinding Conference SME, Cincinnati, Ohio, October 4-7, 1999.

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

JEDRZEJEWSKI J. e MODRZYCKI W. **Intelligent supervision of thermal deformations in high precision machine tools**. Proc. 32nd Int. MATADOR Conf, Manchester, UK, pp. 457-462, 1997.

JEMIELNIAK, K. **Some Aspects of Acoustic Emission Signal Processing**. Annals of the CIRP, pp. 1-8, 1997.

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, Brasil, 138p, 1996.

KANNAPPAN, S. e MALKIN, S. **Effects of the Grain Size and Operation Parameters on the Mechanics of Grinding**. ASME Journal of Engineering for Industry, Vol. 94, p.838-842, 1972.

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

KLUFT, W. **A Monitoração dos Processos Reduz Custos e Desperdícios**. Revista Máquinas & Metais, vol. 10, pp. 60-80, Outubro 1994.

KNIFECO. **Guia dos principais aços modernos destinados à cutelaria**. Disponível em: <<http://www.knifeco.ppg.br/acos.htm>>. Acesso em: março, 2004.

KOHLI, S. P.; GUO, C. e MALKIN, S. **Energy partition for grinding with aluminum oxide and CBN abrasive wheels**. ASME Journal of Engineering for Industry, v.117, p.160-168, 1995.

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

KOVACEVIC, R. e MOHAN R. **Effect of high speed grinding fluid on surface grinding performance**. SME Technical paper MR95-213, p. 919-931, 1995.

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 41, pp. 899–913, 2001.

LAVINE, A. S.; MALKIN, S.; JEN, T. C. **Thermal aspects of grinding with CBN abrasives**. Annals of the CIRP, v.38/1, p.557-560, 1989.

LINDSAY, R. P. **The effect of contact time on forces, wheel wear rate and G-ratio during internal and external grinding.** In: Annals of the CIRP, 33/1, p.193-197, 1984.

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

MALKIN, S. **Current trends in CBN grinding technology.** Annals of the CIRP., v.34/1, p.557-560, 1985.

MALKIN, S. e COOK, N. H. **The wear of Grinding Wheels, Part 1, Attritious Wear.** Trans. ASME, J. of Eng.for Ind., 93, p.1129, 1971.

MONICI, R. D. **Análise da mínima quantidade de refrigeração e da refrigeração convencional na retificação de aços endurecidos.** Dissertação (Mestrado em Engenharia Industrial) – Faculdade de Engenharia – UNESP, Bauru, 2002.

NATHAN, R. D.; VIJAYARAGHAVAN, L.; KRISHNAMURTHY, R. **In process monitoring of burn in the cylindrical grinding of steel.** Department of Mechanical Engineering, Indian Institute of technology – Journal of Materials Processing Technology 91 pp. 37-42, 1999.

NAVAUX, P. O. A. e BOSCHETTI, M. R. **Redes Neurais Artificias SOM (Kohonen).** Disponível em: <<http://www.inf.ufrgs.br/procpar/disc/cmp135/trabs/012/T2/marcos/rnasom.htm>>. Acesso em: abril, 2004.

OLIVEIRA, A. C. **Aplicação – Redes neurais.** Disponível em: <http://equipe.nce.ufrj.br/thome/grad/nn/mat_didatico/ic_grad2002_aula4.pdf>. Acesso em: março, 2004.

OLIVEIRA, J. F. G. **Tópicos Avançados sobre o Processo de Retificação.**, EESC, USP, São Carlos, Publicação 048/89, 1989.

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

OLIVEIRA, J. F. G.; BIANCHI, E. C. e SOUZA, G. F. **O desempenho de rebolos pode ser controlado pela dressagem.** Revista Máquinas & Metais, Aranda Editora, ano XXVIL, nº317, pp. 12-25, junho, 1992.

OLIVEIRA, J. F. G.; BICUDO, L. A. M. C.; SOKOLOWSKI, A. **O uso de redes neurais para a modelagem da deformação térmica em retificadoras.** Revista Máquinas e Metais, São Paulo, v. 363, p. 112- 123, 01 abr. 1996.

OLIVEIRA, J. F. G.; SILVA, E. J.; BIFFI, M. **New architecture control system for an intelligent high speed grinder.** Abrasives Magazine, October/November, 2002.

PARK, C.W.; KIM, D.E.; LEE, S. J. **Shape prediction during the cylindrical traverse grinding of a slender workpiece.** Journal of Materials Processing Technology 88, p.23-32, 1999.

RABELLO, R. S. **Redes neurais artificiais.** Disponível em: <<http://lci.upf.tche.br/~roberto/rnr/IA%20-%2028-10-02/Redes%20Neurais%20-%20passo%20a%20passo.htm>>. Acesso em: março, 2004.

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

ROUSE, H.; ASCE, M.; HOWE, J.W; METZLER, D.E.; **Experimental investigation of fire monitors and nozzles.** 117h ASCE Transactions, 1952.

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

RUNGE, P. R. F.; DUARTE, G. N. **Lubrificantes nas industrias.** Triboconcept - Edições Técnicas, Brasil, 323 p, 1989.

SILVA, E. J. **Análise da influência dos tipos de fluido de corte e rebolo na retificação do aço SAE HVN-3**. Dissertação (Mestrado em Engenharia Industrial) – Faculdade de Engenharia – UNESP, Bauru, 2000.

SOARES, D. D. e OLIVEIRA, J. F. G. **Diagnóstico de processos de retificação pela análise de sinais**. Revista Máquina & Metais, nº 436, p.140 – 157, Maio, 2002.

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: fevereiro, 2004a.

TAFNER, M. A. **O que são as redes neurais artificiais**. Disponível em: <<http://www.cerebromente.org.br/n05/tecnologia/rna.htm>>. Acesso em: fevereiro, 2004b.

TANURI, M. G. **Inteligência Artificial: Novas Perspectivas**. Disponível em: <<http://www.facom.ufba.br/acm/gabriela.html>>. Acesso em: janeiro, 2004.

TATIBANA, C. Y. e KAETSU, D. Y. **Seja bem vindo à homepage de Redes Neurais**. Disponível em: < <http://www.din.uem.br/ia/neurais/>>. Acesso em: janeiro, 2004.

TAYLOR-HONSON (2000) – **Manual da Máquina Talyround 31C**.

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, pp. 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: março, 2004.

TÖNSHOFF, H. K. e GRABNER, T. **Cylindrical and Profile Grinding with Boron Nitride Wheels**. Proceedings of the 5th International Conference on Production Engineering, Tóquio, p. 326-343, 1984.

VANSEVENANT, I. R. E. **An Improved Mathematical Model to Predict Residual Stresses in Surface Plunge Grinding**. Annals of the CIRP., 36, p. 413-416, 1989.

VIEIRA JÚNIOR, M.; LIBARDI, R.; CANCELIERI, H. A.; LIMA, A. **Como o calor pode afetar a integridade superficial das peças**. Revista Máquina & Metais, nº 397, p.28-36, Fevereiro, 1999.

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

VIJAYARAGHAVAN, L.; KRISHNAMURTHY, R., 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.; WILLETT, P.; AGUIAR, P. R.; WEBSTER, J. **Neural Network Detection Grinding Burn from Acoustic Emission..** International Journal of Machine Tools & Manufacture, volume 41, pp. 283-309, 2001.

WEBSTER, J. **Optimizing coolant application systems for high productivity grinding**. ABRASIVES Magazine, October/November de 1999.

WEBSTER, J. **Selection of coolant type and application technique in grinding**. Supergrind, p. 205-218, 1995.

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