

UNIVERSIDADE FEDERAL DE SANTA CATARINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

**APLICAÇÃO DE MULTISENORES NO PROGNÓSTICO DA  
VIDA DA FERRAMENTA DE CORTE EM TORNEAMENTO**

Tese submetida à UNIVERSIDADE FEDERAL DE SANTA CATARINA  
para obtenção do grau de DOUTOR EM ENGENHARIA MECÂNICA

**ANDRÉ JOÃO DE SOUZA**

Florianópolis, setembro de 2004.

UNIVERSIDADE FEDERAL DE SANTA CATARINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

APLICAÇÃO DE MULTISENORES NO PROGNÓSTICO DA  
VIDA DA FERRAMENTA DE CORTE EM TORNEAMENTO

**André João de Souza**

Esta tese foi julgada adequada para a obtenção do título de **Doutor em Engenharia**,  
especialidade **Engenharia Mecânica**, sendo aprovada em sua forma final.

---

**Prof. Walter Lindolfo Weigaertner, Dr.-Ing.** – Orientador (EMC-UFSC)

---

**Prof. Guilherme Bittencourt, Dr.Rer.Nat.** – Co-orientador (DAS-UFSC)

---

**Prof. José Antônio Bellini da Cunha Neto, Dr.** – Coordenador do Curso

**Banca Examinadora**

---

**Prof. Walter Lindolfo Weigaertner, Dr.-Ing.** - Presidente

---

**Prof. Anselmo Eduardo Diniz, Dr. Eng.** - Relator (FEM-UNICAMP)

---

**Prof. Reginaldo Teixeira Coelho, Ph.D.** (EESC-USP)

---

**Prof. Mauro Roisenberg, Dr. Eng.** (INE-UFSC)

---

**Prof. Rolf Bertrand Schroeter, Dr. Eng.** (EMC-UFSC)



*Pedi **força**... E Deus me deu dificuldades para eu me fortalecer.*

*Pedi **sabedoria**... E Deus me deu problemas para resolver.*

*Pedi **prosperidade**... E Deus me deu saúde e inteligência para trabalhar.*

*Pedi **coragem**... E Deus me deu obstáculos para superar.*

*Pedi **amor**... E Deus me deu pessoas com problemas para ajudar.*

*Pedi **favores**... E Deus me deu oportunidades.*

*Não recebi **nada** que pedi... Mas recebi **tudo** que precisava.*



À minha esposa **Elisabete** ♥, minha alma gêmea,  
e à minha filha **Gabriele** 🌸, minha maior realização.

## AGRADECIMENTOS



*"Se você se sente só é porque construiu muros em vez de pontes".*

ANÔNIMO

Ao Prof. Walter pela oportunidade, orientação e amizade.

Ao Prof. Guilherme pela colaboração, co-orientação e amizade.

Ao Prof. Rolf pela rica co-orientação "informal", pela sinceridade e pela amizade.

Ao Conselho Nacional de Pesquisa e Desenvolvimento Tecnológico (CNPq) pela bolsa de estudos concedida.

Aos futuros engenheiros do grupo SIMAP (LMP): Giancarlo, Rafael, Tiago, Felipe e Paulo pelo companheirismo e pelo grande apoio nas horas mais difíceis.

À SANDVIK COROMANT pelas ferramentas de corte (insertos).

À SENSIS<sup>®</sup> São Carlos, pelo empréstimo do Sistema Monitor de Emissão Acústica.

Ao Dr.-Ing. Werner Klufft (Prometec GmbH), pelas informações, críticas e sugestões sobre a proposta da tese, num momento de importante decisão.


Àqueles que possibilitaram a viagem de intercâmbio tecnológico entre Brasil e Alemanha: Dr. Lotter (TU-Ilmenau), Prof. Höhne (TU-Ilmenau) e Prof. Forcelini (UFSC).

A todos aqueles do Laboratório de Mecânica de Precisão que colaboraram direta ou indiretamente na condução do trabalho.

A Deus, por tudo.

## SUMÁRIO

---



<b>LISTA DE FIGURAS .....</b>	<b>iv</b>
<b>LISTA DE TABELAS.....</b>	<b>ix</b>
<b>LISTA DE ABREVIATURAS E SIGLAS.....</b>	<b>x</b>
<b>LISTA DE SÍMBOLOS .....</b>	<b>xii</b>
Alfabeto Latino .....	xii
Alfabeto Grego.....	xiv
<b>BIOGRAFIA DO AUTOR.....</b>	<b>xv</b>
<b>RESUMO .....</b>	<b>xvi</b>
Palavras-chave .....	xvi
<b>ABSTRACT .....</b>	<b>xvii</b>
Keywords .....	xvii
<b>1 - INTRODUÇÃO .....</b>	<b>1</b>
1.1 Objetivos.....	4
1.2 Justificativas para a Implementação.....	4
1.3 Originalidade .....	5
1.4 Contribuições.....	6
1.5 Estrutura do Trabalho .....	7
<b>2 - FUNDAMENTOS DO PROCESSO DE TORNEAMENTO .....</b>	<b>11</b>
2.1 Variáveis Envolvidas no Processo .....	12
2.1.1 Variáveis Independentes de Entrada.....	14
2.1.2 Variáveis Dependentes .....	17
<b>3 - VIDA DA FERRAMENTA.....</b>	<b>25</b>
3.1 Mecanismos e Processos de Falhas.....	25
3.2 Desgastes e Avarias da Ferramenta.....	29
3.3 Vida da Ferramenta.....	31


<b>4 - FORMULAÇÃO DO PROBLEMA.....</b>	<b>35</b>
4.1 Resposta Imediata à Colisão.....	36
4.2 Estimativa ou Classificação de Falhas Contínuas .....	37
4.3 Identificação de Falhas Transitórias .....	38
<b>5 - MONITORAMENTO DO ESTADO DA FERRAMENTA .....</b>	<b>41</b>
5.1 Sensoriamento .....	43
5.1.1 Medição Direta.....	45
5.1.2 Medição Indireta .....	45
5.1.3 Aplicação de um Sensor .....	46
5.1.4 Aplicação de Múltiplos Sensores.....	47
5.2 Condicionamento de Sinais .....	48
5.2.1 Pré-processamento Analógico .....	49
5.2.2 Pré-processamento Digital .....	50
5.3 Tratamento de Sinais.....	51
5.3.1 Extração de Características no Domínio do Tempo .....	52
5.3.2 Extração de Características no Domínio da Frequência .....	55
5.3.3 Extração de Características no Domínio Tempo-Frequência.....	57
5.3.4 Seleção das Características .....	58
5.4 Reação ou Tomada de Decisão .....	59
5.4.1 Reconhecimento de Padrões de Falha .....	60
5.4.2 Inteligência Computacional (Soft Computing).....	63
5.5 Sistemas de Monitoramento Comercializados .....	72
<b>6 - RECONHECIMENTO DA FALHA VIA SINAIS INDIRETOS .....</b>	<b>75</b>
6.1 Força de Usinagem .....	77
6.2 Vibração.....	81
6.3 Emissão Acústica .....	83
6.4 Outros Métodos.....	87
<b>7 - REDES NEURAIS ARTIFICIAIS .....</b>	<b>91</b>
7.1 Modelo de McCulloch e Pitts .....	92
7.2 Estrutura Geral para Redes Neurais Artificiais .....	93
7.3 Topologia de Redes Neurais Artificiais .....	96
7.4 Treinamento em Redes Neurais Artificiais .....	99
7.4.1 Treinamento Supervisionado.....	100
7.4.2 Treinamento Não-supervisionado .....	106
7.4.3 Sobre-treinamento e Sub-treinamento .....	108
7.5 Estimativa, Classificação ou Identificação (Tomada de Decisão) .....	109
<b>8 - FORMAÇÃO DA BASE DE CONHECIMENTO.....</b>	<b>111</b>
8.1 Arquitetura do Sistema Experimental .....	112
8.1.1 Corpo de Prova .....	113
8.1.2 Máquina-ferramenta.....	115
8.1.3 Ferramenta de Corte .....	115
8.1.4 Sistema de Medição Direta .....	116
8.1.5 Sistema de Monitoramento Indireto.....	117
8.1.6 Sistema de Medição de Rugosidade.....	123

8.2	Considerações Preliminares .....	123
8.2.1	Análise da Influência dos Parâmetros de Corte na Rugosidade e nos Sinais de Força e Vibração .....	124
8.2.2	Determinação Empírica do Tempo de Vida da Ferramenta .....	130
8.3	Ensaio Realizados e Resultados Alcançados .....	132
8.3.1	Análise de Sinais de Força .....	133
8.3.2	Análise de Sinais de Vibração .....	141
8.3.3	Análise de Sinais de Emissão Acústica .....	146
8.3.4	Análise de Rugosidade .....	148
8.4	Determinação das Regras de Inferência .....	149
8.4.1	Estimativa da Largura do Desgaste de Flanco .....	150
8.4.2	Detecção de Avarias (lascamento e quebra) .....	151
8.5	Testes Iniciais com RNA via MATLAB <sup>o</sup> .....	152
<b>9</b>	<b>- PROPOSTA DE UM SISTEMA MONITOR INTELIGENTE.....</b>	<b>157</b>
9.1	Aquisição de Sinais via Múltiplos Sensores .....	157
9.2	Tratamento de Sinais e Extração de Características .....	158
9.3	Processamento Paralelo de Informações .....	159
9.4	Identificação do Estado da Ferramenta.....	159
9.5	Prognóstico do Fim de Vida .....	160
<b>10</b>	<b>- IMPLEMENTAÇÃO DO SISTEMA MONITOR.....</b>	<b>163</b>
10.1	Arquitetura do Sistema .....	163
10.2	Aplicação do Sistema .....	165
10.2.1	Detecção de Avarias .....	167
10.2.2	Estimativa da Marca de Desgaste de Flanco .....	170
10.2.3	Tempo Restante Estimado.....	172
<b>11</b>	<b>- CONCLUSÕES E PERSPECTIVAS.....</b>	<b>175</b>
11.1	Capacidade do Sistema.....	175
11.1.1	Estimativa dos Valores de VB .....	176
11.1.2	Detecção de avarias.....	176
11.1.3	Prognóstico da vida da ferramenta .....	176
11.2	Limitações .....	177
11.3	Tendências e Direções .....	177
11.4	Propostas para Trabalhos Futuros .....	178
<b>REFERÊNCIAS.....</b>		<b>181</b>
Bibliografia Complementar .....		198
<b>ANEXOS .....</b>		<b>203</b>
A1	Calibração da Plataforma Piezelétrica 9257A .....	203
A2	Valores de Força, Vibração, Rugosidade e Tempo de Vida da Ferramenta para Diferentes Parâmetros de Usinagem .....	205
A3	Variações Percentuais dos Sinais de Força .....	206
A4	Resultados Finais (Tabelados) .....	210



## LISTA DE FIGURAS

---



<b>Figura 2.1</b> – Operações de torneamento [32].....	12
<b>Figura 2.2</b> – Relações de entrada e saída em torneamento [33].....	13
<b>Figura 2.3</b> – Principais tipos de cavaco [19] .....	18
<b>Figura 2.4</b> – Dependência das componentes das forças de usinagem em relação a: (a) avanço; (b) velocidade de corte; (c) profundidade de corte; (d) ângulo de posição [19] .....	19
<b>Figura 2.5</b> – Distribuição de (a) calor e (b) temperatura na interface peça-cavaco-ferramenta durante a usinagem de aço [19; 32] .....	21
<b>Figura 2.6</b> – Vibração <i>chatter</i> detectada no torneamento a seco do aço ABNT 1040 usando inserto de metal-duro. Parâmetros: $f = 0,3$ mm, $v_c = 350$ m/min e $a_p = 1,5$ mm .....	22
<b>Figura 2.7</b> – Tipos de falha na ferramenta de corte em torneamento [19] .....	23
<b>Figura 2.8</b> – Classificação de acabamento [20] .....	23
<b>Figura 3.1</b> – Esquema dos tipos de desgaste da ferramenta de corte: (a) desgaste de cratera; (b) desgaste de flanco; (c) e (d) entalhe [20] .....	29
<b>Figura 3.2</b> – Padrão de desgaste para uma ferramenta de metal-duro [16; 40].....	30
<b>Figura 4.1</b> – Custo estimado dos eventos em usinagem [3] .....	36
<b>Figura 4.2</b> – Fotos do gume de um inserto de metal-duro em torneamento a seco do aço ABNT 1040 com $f = 0,3$ mm, $v_c = 350$ m/min e $a_p = 1,5$ mm em tempos de vida diferentes .....	38
<b>Figura 4.3</b> – Foto do gume de um inserto de metal-duro em torneamento a seco do aço ABNT 1040 com $f = 0,3$ mm, $v_c = 350$ m/min e $a_p = 1,5$ mm fraturado .....	39
<b>Figura 5.1</b> – Processo de elaboração de um sistema de monitoramento [49] .....	42
<b>Figura 5.2</b> – Sistema de monitoramento do estado da ferramenta [50] .....	42
<b>Figura 5.3</b> – Sistema inteligente de monitoramento do estado da ferramenta [51] .....	43
<b>Figura 5.4</b> – Pré-processamento digital de sinais analógicos [80] .....	49
<b>Figura 5.5</b> – Diretrizes para o processamento de sinais sensórios [84].....	51
<b>Figura 5.6</b> – Representação típica da Transformada de Fourier. Diagrama representando amplitude e frequência de cada senoide [95] .....	56
<b>Figura 5.7</b> – Representação da incerteza [110] .....	59
<b>Figura 5.8</b> – Limite dinâmicos [9] .....	61
<b>Figura 5.9</b> – Detecção da fratura em duas situações distintas [111] .....	62

<b>Figura 5.10</b> – Padrões de referência na detecção da fratura da ferramenta [13; 112].....	63
<b>Figura 5.11</b> – Exemplo de uma rede neural artificial tipo MLP [118; 119; 123–126].....	66
<b>Figura 5.12</b> – Ilustração do conceito de estratégia nebulosa [75; 76].....	68
<b>Figura 5.13</b> – Aplicação da lógica nebulosa na classificação de desgastes [26].....	69
<b>Figura 5.14</b> – Tipos de combinação entre RNA e LNB [26].....	69
<b>Figura 5.15</b> – Aplicação do sistema SOSAFM na estimativa de valores de VB [130; 131; 132].....	70
<b>Figura 5.16</b> – Comparação entre RNA, LNB e SNF na estimativa de VB [133].....	71
<b>Figura 6.1</b> – Estágios de desenvolvimento do desgaste de flanco [40].....	75
<b>Figura 6.2</b> – Componentes ortogonais da força de usinagem no torneamento [11; 31; 75; 76; 138; 139].....	77
<b>Figura 6.3</b> – Parcelas estática e dinâmica da força de usinagem em função do tempo de usinagem (condições fixas de corte) [11].....	80
<b>Figura 6.4</b> – Sinais de vibração da ferramenta de metal-duro no torneamento a seco do aço ABNT 1040 com $f = 0,3$ mm, $v_c = 350$ m/min e $a_p = 1,5$ mm em tempos de vida diferentes.....	82
<b>Figura 6.5</b> – EA gerada no processo de corte [59; 88; 152; 153; 155; 157; 161].....	84
<b>Figura 6.6</b> – Tipos de sinais de EA em processos de usinagem [156].....	84
<b>Figura 6.7</b> – EA para diferentes velocidades de corte [16].....	85
<b>Figura 6.8</b> – Detecção da fratura a partir de $K_\beta$ do sinal de EA no torneamento do aço 1045 usando ferramenta P30 com $f = 0,33$ mm, $v_c = 260$ m/min e $a_p = 2,5$ mm [90].....	86
<b>Figura 6.9</b> – Tons de cinza em função do desgaste da ferramenta P15 no torneamento do aço 1045 usando $f = 0,50$ mm, $v_c = 497$ m/min e $a_p = 0,40$ mm [174].....	89
<b>Figura 7.1</b> – Neurônio biológico.....	92
<b>Figura 7.2</b> – Estrutura geral de um neurônio artificial [119; 128; 177].....	93
<b>Figura 7.3</b> – Topologia para RNA: (a) sem realimentação e camadas isoladas; (b) sem realimentação com conexões diretas entre as camadas de entrada e saída; (c) com realimentação [128].....	96
<b>Figura 7.4</b> – Exemplo de rede neural artificial direta [118; 119; 125; 145; 180].....	97
<b>Figura 7.5</b> – Efeitos da camada oculta numa rede neural artificial [76].....	98
<b>Figura 7.6</b> – Percentual de aplicações das estruturas das RNA's em TCM (adaptado de [12]).....	99
<b>Figura 7.7</b> – Treinamento supervisionado de redes neurais artificiais [181].....	99
<b>Figura 7.8</b> – Modelo de uma operação de torneamento [52; 79].....	102
<b>Figura 7.9</b> – Mapas auto-organizáveis de Kohonen [185].....	107
<b>Figura 7.10</b> – Representação do sobre-treinamento [181].....	108
<b>Figura 8.1</b> – Arquitetura do sistema experimental completo.....	112
<b>Figura 8.2</b> – Microestrutura do material.....	113
<b>Figura 8.3</b> – Perfil de dureza do material do corpo de prova.....	114
<b>Figura 8.4</b> - Torno CNC ROMI <sup>®</sup> COSMOS 20-U.....	115
<b>Figura 8.5</b> – Ferramenta de corte T-Max P Sandvik Coromant [191].....	116
<b>Figura 8.6</b> – Sistema de medição direta via câmera CCD.....	117
<b>Figura 8.7</b> – Plataforma piezométrica KISTLER <sup>®</sup> 9257 <sup>a</sup> .....	118
<b>Figura 8.8</b> – Sensor de vibração e/ou ultra-som PROMETEC <sup>®</sup> AE 30.....	118

<b>Figura 8.9</b> – Sensor de emissão acústica SENSIS® .....	118
<b>Figura 8.10</b> – Amplificador de carga KISTLER® 5011 .....	119
<b>Figura 8.11</b> – Pré-amplificador PROMETEC® GDV .....	119
<b>Figura 8.12</b> – Sistema monitor de emissão acústica SENSIS® BM-12 .....	120
<b>Figura 8.13</b> – Placa de conexão NATIONAL INSTRUMENTS® modelo SCB-68 .....	122
<b>Figura 8.14</b> – Rugosímetro Portátil MITUTOYO® SJ-201 .....	123
<b>Figura 8.15</b> – Relação entre força de avanço e os parâmetros de corte .....	125
<b>Figura 8.16</b> – Relação entre força de avanço normalizada e os parâmetros de corte .....	125
<b>Figura 8.17</b> – Relação entre força passiva e os parâmetros de corte .....	126
<b>Figura 8.18</b> – Relação entre força passiva normalizada e os parâmetros de corte.....	126
<b>Figura 8.19</b> – Relação entre força de corte e os parâmetros de corte .....	127
<b>Figura 8.20</b> – Relação entre força de corte normalizada e os parâmetros de corte .....	127
<b>Figura 8.21</b> – Relação entre o sinal de vibração e os parâmetros de corte .....	128
<b>Figura 8.22</b> – Relação entre o desvio médio de rugosidade e os parâmetros de corte .....	129
<b>Figura 8.23</b> – Relação entre o sinal de vibração e o desvio médio de rugosidade .....	129
<b>Figura 8.24</b> – Curva de vida das ferramentas.....	131
<b>Figura 8.25</b> – Tempos de vida dos gumes analisados .....	131
<b>Figura 8.26</b> – Sistema de medição de força em torneamento.....	133
<b>Figura 8.27</b> – VB em função do tempo de corte para 4 gumes.....	134
<b>Figura 8.28</b> – Força de avanço em função do tempo de usinagem .....	135
<b>Figura 8.29</b> – Força passiva em função do tempo de usinagem .....	135
<b>Figura 8.30</b> – Força de corte em função do tempo de usinagem .....	135
<b>Figura 8.31</b> – Força de avanço normalizada em função do tempo de usinagem .....	136
<b>Figura 8.32</b> – Força passiva normalizada em função do tempo de usinagem.....	137
<b>Figura 8.33</b> – Força de corte normalizada em função do tempo de usinagem .....	137
<b>Figura 8.34</b> – Relação “R <sub>1</sub> ” em função do tempo de usinagem .....	138
<b>Figura 8.35</b> – Relação “R <sub>2</sub> ” em função do tempo de usinagem .....	138
<b>Figura 8.36</b> – Relação “R <sub>3</sub> ” em função do tempo de usinagem .....	139
<b>Figura 8.37</b> – Forças após 30 segundos.....	140
<b>Figura 8.38</b> – Forças após 13 minutos.....	140
<b>Figura 8.39</b> – Forças após 17 minutos.....	140
<b>Figura 8.40</b> – Forças após 18 minutos.....	140
<b>Figura 8.41</b> – Variação percentual das forças em função do tempo de usinagem .....	141
<b>Figura 8.42</b> – Sistema de medição de vibração em torneamento.....	142
<b>Figura 8.43</b> – Vibração após 30 segundos .....	143
<b>Figura 8.44</b> – Vibração após 13 minutos.....	143
<b>Figura 8.45</b> – Vibração após 17 minutos.....	143

<b>Figura 8.46</b> – Vibração após 18 minutos .....	143
<b>Figura 8.47</b> – Vibração em função do tempo de corte.....	144
<b>Figura 8.48</b> – Variação percentual da vibração e da força passiva em função do tempo de corte.....	144
<b>Figura 8.49</b> – Amostragem concatenada de pontos ( $V_{RMS}$ ) em função do tempo de corte.....	145
<b>Figura 8.50</b> – “ $S_{\beta}$ ” e “ $K_{\beta}$ ” após 30 segundos .....	145
<b>Figura 8.51</b> – “ $S_{\beta}$ ” e “ $K_{\beta}$ ” após 13 minutos .....	145
<b>Figura 8.52</b> – “ $S_{\beta}$ ” e “ $K_{\beta}$ ” após 17 minutos .....	146
<b>Figura 8.53</b> – “ $S_{\beta}$ ” e “ $K_{\beta}$ ” após 18 minutos .....	146
<b>Figura 8.54</b> – Sistema de medição de emissão acústica em torneamento.....	147
<b>Figura 8.55</b> – Sinais de EA após filtragens (FPA e FPB) [194; 195] .....	147
<b>Figura 8.56</b> – “ $R_a$ ” em função do tempo para o gume 4 .....	149
<b>Figura 8.57</b> – “ $R_a$ ” em função de VB para o gume 4 .....	149
<b>Figura 8.58</b> – Tempos de vida dos gumes considerados no treinamento da FFBPNN.....	153
<b>Figura 8.59</b> –Valores estimados de VB do gume 14 usando uma RNA 5-20-1 com treinamento por retropropagação flexível (1000 iterações).....	154
<b>Figura 8.60</b> –Valores estimados de VB do gume 7 usando uma RNA 5-20-1 com treinamento por retropropagação flexível (1000 iterações).....	155
<b>Figura 9.1</b> – Tempo de vida em função de VB .....	160
<b>Figura 9.2</b> – Tempo de vida restante em função de VB .....	161
<b>Figura 9.3</b> – Relação entre os tempos reais e estimados do tempo de vida restante ao gume 7.....	161
<b>Figura 9.4</b> – Relação entre os tempos reais e estimados do tempo de vida restante ao gume 14.....	162
<b>Figura 10.1</b> – Arquitetura do Sistema Monitor .....	164
<b>Figura 10.1</b> – Curva de vida das ferramentas A, B e C .....	165
<b>Figura 10.2</b> – Fotos dos gumes A, B e C anteriormente ao lascamento (desgaste avançado).....	166
<b>Figura 10.3</b> – Fotos dos gumes A, B e C lascados.....	166
<b>Figura 10.4</b> – Detecção da fratura do gume A: força e emissão acústica.....	167
<b>Figura 10.5</b> – Detecção da fratura do gume A: vibração .....	167
<b>Figura 10.6</b> – Detecção da fratura do gume B: componentes normalizadas da força de usinagem .....	168
<b>Figura 10.7</b> – Detecção da fratura do gume B: vibração .....	168
<b>Figura 10.8</b> – Detecção da fratura do gume B: componentes normalizadas da força de usinagem .....	169
<b>Figura 10.9</b> – Detecção da fratura do gume C: vibração .....	169
<b>Figura 10.10</b> – Detecção da fratura do gume C: emissão acústica.....	169
<b>Figura 10.11</b> – Comparação entre os valores estimados e reais de VB para o gume A .....	170
<b>Figura 10.12</b> – Comparação entre os valores estimados e reais de VB para o gume B .....	171
<b>Figura 10.13</b> – Comparação entre os valores estimados e reais de VB para o gume C .....	171
<b>Figura 10.14</b> – Tempo de vida restante para o gume A .....	172
<b>Figura 10.15</b> – Indicação do fim de vida do gume A pelo sistema monitor .....	172
<b>Figura 10.16</b> – Tempo de vida restante para o gume B .....	173

<b>Figura 10.17</b> – Indicação do fim de vida do gume B pelo sistema monitor.....	173
<b>Figura 10.18</b> – Tempo de vida restante para o gume C.....	174
<b>Figura 10.19</b> – Indicação do fim de vida do gume C pelo sistema monitor.....	174
<b>Figura A.1</b> – Procedimento de calibração da plataforma piezolétrica 9257A.....	203
<b>Figura A.2</b> – Análise de regressão para o canal X da plataforma 9257A.....	204
<b>Figura A.3</b> – Análise de regressão para o canal Y da plataforma 9257A.....	204
<b>Figura A.4</b> – Análise de regressão para o canal Z da plataforma 9257A.....	205
<b>Figura A.5</b> – Variação percentual de “ $F_t$ ” com o aumento de “VB”.....	207
<b>Figura A.6</b> – Variação percentual de “ $F_p$ ” com o aumento de “VB”.....	207
<b>Figura A.7</b> – Variação percentual de “ $F_c$ ” com o aumento de “VB”.....	207
<b>Figura A.8</b> – Variação percentual de “ $NF_t$ ” com o aumento de “VB”.....	208
<b>Figura A.9</b> – Variação percentual de “ $NF_p$ ” com o aumento de “VB”.....	208
<b>Figura A.10</b> – Variação percentual de “ $NF_c$ ” com o aumento de “VB”.....	208
<b>Figura A.11</b> – Variação percentual de “ $R_1$ ” com o aumento de “VB”.....	209
<b>Figura A.12</b> – Variação percentual de “ $R_2$ ” com o aumento de “VB”.....	209
<b>Figura A.13</b> – Variação percentual de “ $R_3$ ” com o aumento de “VB”.....	209

## LISTA DE TABELAS

---



<b>Tabela 2.1</b> – Influência dos ângulos de saída e folga nas componentes das forças de usinagem [19] .....	16
<b>Tabela 5.1</b> – Exemplos de métodos de medição direta e indireta .....	44
<b>Tabela 5.2</b> – Necessidades das aplicações em monitoramento e diagnóstico .....	64
<b>Tabela 5.3</b> – Propriedades fundamentais dos métodos de conhecimento.....	65
<b>Tabela 5.4</b> – Relação entre os métodos de conhecimento e suas aplicações .....	65
<b>Tabela 7.1</b> – Funções de ativação mais empregadas [117; 119; 180; 181].....	95
<b>Tabela 8.1</b> – Composição química do material do corpo de prova .....	114
<b>Tabela 8.2</b> – Parâmetros de corte escolhidos para a análise .....	124
<b>Tabela 8.3</b> – Parâmetros de corte escolhidos para a determinação dos índices de monitoramento.....	132
<b>Tabela 8.4</b> – Relação entre o aumento percentual das componentes da força de usinagem e o valor de VB .....	136
<b>Tabela 8.5</b> – Relação entre a variação percentual das componentes normalizadas e o valor de VB .....	138
<b>Tabela 8.6</b> – Relação entre as variações percentuais de “R <sub>1</sub> ”, “R <sub>2</sub> ” e “R <sub>3</sub> ” e o valor de “VB” .....	139
<b>Tabela 8.7</b> – Configurações de redes FFNN usadas nos testes .....	153
<b>Tabela 8.8</b> – Melhores resultados dos algoritmos de treinamento para os gumes 7 e 14 .....	153
<b>Tabela 8.9</b> – Melhores resultados dos algoritmos de treinamento para as configurações 1 e 3.....	154
<b>Tabela A.1</b> – Combinações dos parâmetros de corte escolhidos para a análise .....	206
<b>Tabela A.2</b> – Resultados obtidos para o gume A .....	210
<b>Tabela A.3</b> – Resultados obtidos para o gume B .....	211
<b>Tabela A.4</b> – Resultados obtidos para o gume C .....	211

## LISTA DE ABREVIATURAS E SIGLAS



ABNT	Associação Brasileira de Normas Técnicas
ASTM	Sociedade Americana para Testes e Materiais ( <i>American Society for Testing and Materials</i> )
ADC	conversor de sinais analógicos para digitais ( <i>analog to digital converter</i> )
AR	auto-regressão ( <i>auto-regressive</i> )
ARMA	auto-regressão com média móvel ( <i>auto-regressive moving average</i> )
ART	teoria da ressonância adaptativa ( <i>adaptive resonance theory</i> )
BP	retropropagação ( <i>back-propagation</i> )
CBN	nitreto de boro cúbico ( <i>cubic boron nitride</i> )
CCD	detector de carga acoplada ( <i>charge couple device</i> )
CE	camada de entrada de uma rede neural artificial
CERMET	material composto de ferramenta de corte (cerâmica + metal)
CIM	Manufatura Integrada por Computador ( <i>computer-integrated manufacturing</i> )
CNC	Comando Numérico Computadorizado
CO	camada oculta de uma rede neural artificial
CS	camada de saída de uma rede neural artificial
DAC	conversor de sinais digitais para analógicos ( <i>digital to analog converter</i> )
DAQ	aquisição de dados ( <i>data acquisition</i> )
DSP	processador de sinais digitais ( <i>digital signal processor</i> )
EA	emissão acústica
FF	pró-alimentação ( <i>feed-forward</i> )
FFNN	rede neural direta, sem realimentação ( <i>feed-forward neural network</i> )
FFT	transformada rápida de Fourier ( <i>fast Fourier transform</i> )
FMS	Sistema Flexível de Manufatura ( <i>flexible manufacturing system</i> )
FPA	filtro de frequências passa-altas
FPB	filtro de frequências passa-baixas
FPF	filtro de frequências passa-faixa ou passa-banda
FT	transformada de Fourier ( <i>Fourier transform</i> )

FWT	transformada rápida de <i>wavelet</i> ( <i>fast wavelet transform</i> )
HSS	aço-rápido ( <i>high-speed steel</i> )
IT	nível de qualidade de fabricação para o sistema de tolerâncias e ajustes
KFM	mapa de Kohonen ( <i>Kohonen feature map</i> )
KM	distância do centro da cratera ao gume ( <i>Kolkmittenabstand</i> )
KT	profundidade de cratera ( <i>Kolktiefe</i> )
LASER	amplificação de luz por emissão estimulada de irradiação ( <i>light amplification by stimulated emission of radiation</i> )
LED	diodo emissor de luz ( <i>light emission diode</i> )
LNB	lógica nebulosa
LVDT	transdutor diferencial de deslocamento linear ( <i>linear-variable differential transformer</i> )
MLP	Perceptron de multicamadas ( <i>multi-layer perceptron</i> )
P20	grupo de aplicação de ferramenta de metal-duro para usinagem de aços de baixo Cr, aços inoxidáveis, aços fundidos e ferro-fundido maleável de cavaco longo.
RAM	memória de acesso randômico ( <i>random access memory</i> )
RMS	raiz média quadrática ( <i>root-mean square</i> )
RNA	rede neural artificial
RNN	redes neurais recorrentes ( <i>recurrent neural network</i> )
RPD	reconhecimento de padrões
SAE	Sociedade de Engenheiros da Mobilidade ( <i>Society of Automotive Engineering</i> )
SNF	sistemas neuro-nebulosos
SOM	mapa auto-organizável de Kohonen ( <i>self-organizing map</i> )
SOSAFM	modelo nebuloso auto-organizável e auto-ajustável ( <i>self-organizing and self-adjusting fuzzy model</i> )
TCM	Monitoramento do Estado da Ferramenta ( <i>Tool Condition Monitoring</i> )
TiC	carboneto de titânio
TiN	nitreto de titânio
VB	largura da marca de desgaste de flanco ( <i>Verschleißmarkenbreite</i> )
VB <sub>B</sub>	largura média da marca de desgaste de flanco
VB <sub>C</sub>	largura da marca do desgaste de entalhe no flanco secundário
VB <sub>máx</sub>	largura máxima da marca de desgaste de flanco
VB <sub>N</sub>	largura da marca do desgaste de entalhe no flanco principal
VI	vibração
WT	transformada de <i>wavelet</i> ( <i>wavelet transform</i> )



## LISTA DE SÍMBOLOS



### Alfabeto Latino

$a$	aceleração; parâmetro da distribuição- $\beta$
$A$	área da seção transversal de corte
AH; BH	categorias classificadas pela <i>hard-decision</i> (booleana)
$a_i$	nível de ativação do neurônio
$a_o$	amplitude de aceleração
$a_p$	profundidade de corte (penetração passiva)
$A_s$ ; $B_s$	categorias classificadas pela <i>soft-decision</i> (nebulosa)
$b$	largura de corte ou do cavaco; parâmetro da distribuição- $\beta$
$b_i$	valor de polarização ou limiar ( <i>bias</i> )
$C_v$	constante que depende do sistema máquina/ ferramenta/ peça e corresponde a uma velocidade de corte que resulta numa vida da ferramenta de 1 minuto
$f$	avanço
$F$	força de usinagem
$F(a_i)$	função de ativação
$F_c$ ou $F_z$	força de corte: equivale à componente tangencial da força de usinagem
$F_D$	parcela dinâmica da força
$F_f$ ou $F_x$	força de avanço: equivale à componente normal da força de usinagem
$F_p$ ou $F_y$	força passiva: equivale à componente radial da força de usinagem
$F_s$	fator amostrado (força)
$g$	expoente do índice de esbeltez do cavaco ( $a_p/f$ )
$h$	espessura de corte ou do cavaco
$i$ , $i'$ e $j$	índices de contagem
$k$	constante
$K_\beta$	curtose ( <i>kurtosis</i> ) da distribuição- $\beta$


$n$	expoente que depende do sistema máquina/ ferramenta/ peça; número de pontos coletados (tamanho da amostra); número de neurónios; número de características de entrada da rede
$N$	número de amostras de treinamento
$NF_c$	força de corte normalizada
$NF_f$	força de avanço normalizada
$NF_p$	força passiva normalizada
$p(x)$	probabilidade da variável aleatória contínua "x"
$r_e$	raio de quina da ferramenta
$R_1$	razão entre a força de avanço e a de corte
$R_2$	razão entre a força passiva e a de corte
$R_3$	relação entre as forças de avanço, passiva e de corte
$R_a$	desvio médio aritmético de rugosidade
$Re$	repetitividade
$R_{max}$	profundidade máxima de rugosidade
$s$	desvio-padrão de uma amostra; expoente da área de seção de corte ( $a_p \cdot f$ )
$S$	fator de escala do amplificador de carga KISTLER®
$S_\beta$	assimetria ( <i>skew</i> ) da distribuição- $\beta$
$T$	sensibilidade do amplificador de carga KISTLER®
$t$	instante de tempo
$T_d$	tendência
$T_{res}$	tempo de vida restante da ferramenta
$T_v$	tempo de vida da ferramenta
$v$	velocidade
$VB_{est}$	largura média da marca de desgaste de flanco estimada
$VB_{real}$	largura média da marca de desgaste de flanco real
$v_c$	velocidade de corte
$VI_x$	vibração na direção normal (avanço)
$VI_y$	vibração na direção radial (passiva)
$v_o$	amplitude de velocidade
$W$	matriz de pesos
$w_{ij}$	peso relativo à entrada do neurônio
$x$	variável aleatória (sinal)
$x_i$	entrada do neurônio
$\bar{X}$	média aritmética de uma amostra
$y$	deslocamento vertical
$y_i$	saída do neurônio
$y_o$	amplitude de deslocamento vertical

## Alfabeto Grego

$\Delta t$	intervalo de tempo
$\mu$	média aritmética de uma população
$\sigma^2; \sigma$	variância e desvio-padrão de uma população, respectivamente
$\alpha$	ângulo de folga da ferramenta, também chamado de ângulo de incidência
$\beta$	ângulo de cunha da ferramenta
$\varepsilon_r$	ângulo de quina da ferramenta, também chamado de ângulo de ponta
$\gamma$	ângulo de saída da ferramenta
$\lambda$	ângulo de inclinação do gume
$\chi_r$	ângulo de posição, também chamado de ângulo de direção do gume, ângulo de rendimento ou ângulo de ataque (também representado por $\chi_r$ )
$\omega$	velocidade angular
$\theta$	ângulo de fase

## BIOGRAFIA DO AUTOR


---



**ANDRÉ JOÃO DE SOUZA** nasceu na cidade de Santo André (SP) em 1971. Estudou em escolas públicas durante toda a sua formação educacional. Em 1988, concluiu o curso **Técnico em Eletrônica** na “Escola Técnica Industrial Lauro Gomes” em São Bernardo do Campo (SP). Trabalhou com técnico na Divisão Avionics da “TAM Jatoss Executivos” nos dois anos seguintes (1989 e 1990). Em 1992, iniciou o curso de **Graduação em Engenharia Mecânica** com habilitação em Mecatrônica pela “Escola de Engenharia de São Carlos” (EESC) da Universidade de São Paulo (USP). Durante a graduação (1992 a 1996), trabalhou como bolsista (CNPq) na área de “Bioengenharia” e estagiou na área de “Robótica”. Em 1996, participou das competições mini-baja pela SAE Brasil (São Paulo – Brasil) e pela SAE Mid-West (Milwaukee – EUA). Também em 1996, estagiou na “Multibrás S.A. Eletrodomésticos” - Unidade Rio Claro (SP) – na área de Engenharia de Manufatura. Em julho de 1999, concluiu o **Mestrado em Engenharia Mecânica** também na EESC-USP, trabalhando no “Laboratório de Otimização de Processos de Fabricação” do “Núcleo de Manufatura Avançada”. Em setembro do mesmo ano, iniciou o **Doutorado em Engenharia Mecânica** na Universidade Federal de Santa Catarina (UFSC). De 2000 a 2003, trabalhou como pesquisador e liderou pesquisas em “Sistemas Inteligentes para Monitoramento e Automação de Processos” no “Laboratório de Mecânica de Precisão” da UFSC. Em 2001, participou de um projeto financiado pelo DAAD que possibilitou a realização de atividades de pesquisa na “Universidade Técnica de Ilmenau” (Alemanha). Desde 2003, atua como **professor** com dedicação tempo integral no curso de “Engenharia Industrial Mecânica” da “Universidade Regional Integrada do Alto Uruguai e das Missões” (URI).

## RESUMO

---



SOUZA, A. J. (2003). **Aplicação de multisensores no prognóstico da vida da ferramenta de corte em torneamento**. Florianópolis/ SC, Tese (Doutorado), POSMEC-UFSC, 211p.


A falha (avaria e/ou desgaste) da ferramenta de corte em usinagem está direta ou indiretamente ligada a diferentes grandezas físicas, relacionadas com o material da peça, o tipo de ferramenta, as condições do processo etc. A análise e a caracterização destas grandezas em tempo real envolve a implementação de sistemas de monitoramento. O sucesso destes sistemas depende da qualidade das informações extraídas dos sinais coletados pelos sensores posicionados em locais estratégicos da máquina-ferramenta, e do algoritmo de inteligência computacional usado para analisá-las e tomar a decisão correta. No primeiro caso, a técnica de multisensores é atrativa, principalmente porque a perda de sensibilidade de um sensor pode ser compensada pela informação captada por outro. No segundo, as redes neurais artificiais destacam-se por suas habilidades em descrever características altamente não-lineares, típicas dos processos de usinagem. Dentro deste enfoque, objetiva-se apresentar o desenvolvimento e a aplicação de um sistema monitor inteligente em torneamento usando a fusão de sinais de força, vibração e emissão acústica com o intuito de reconhecer os padrões de falha da ferramenta de corte (estimativa de desgastes e detecção de avarias) e com isso diagnosticar em tempo real o seu estado. A partir do diagnóstico, o sistema monitor realiza o prognóstico da vida da ferramenta (estimativa do tempo de vida restante) com a ambição de definir o momento mais apropriado para sua troca.

### Palavras-chave

Torneamento; monitoramento da ferramenta; fusão de sensores; redes neurais artificiais.

## ABSTRACT

---




SOUZA, A. J. (2003). **Application on multisensor approach for cutting tool-life prognostication in turning processes**. Florianópolis/ SC; Ph.D. Thesis, POSMEC-UFSC, 211p.

A tool failure (fracture and/or wear) in machining is direct or indirectly associated with distinct physical parameters related to workpiece material, tool type, cutting conditions etc. The on-line analysis and characterization of these parameters involves the implementation of monitoring systems. The success of these systems depends upon both the quality of the information extracted from collected sensor signals strategically placed in the machine tool, and the computational intelligence algorithm used to synthesize them and to make a correct decision. In the first case, a multisensor approach is attractive, mainly because a loss of sensitivity of one sensor can be compensated by the information obtained from the other sensor. In the second, the artificial neural networks have distinction for their abilities in describing high non-linear characteristics current in machining processes. Based on this, a development and application of an intelligent monitor system in turning using force, vibration and acoustic emission sensor signals to recognize the cutting tool failure patterns (wear estimation and fracture detection) and make an on-line tool-state diagnostic is provided. Thus, the monitor system carries out a tool-life prognostication (time-to-end estimation) using the previous tool state diagnostic in order to determine the best moment for tool replacement.

### Keywords

Turning; tool condition monitoring; sensor fusion; artificial neural networks.

# 1 - INTRODUÇÃO



*“De causas aparentemente similares, esperam-se efeitos similares.  
Esta é a somatória de todas as conclusões experimentais”.*

DAVID HUME

Os processos de usinagem passaram nestes últimos anos por profundas mudanças visando, principalmente, o aumento da produtividade e a garantia da qualidade dos produtos fabricados em larga escala. Estas altas taxas de produtividade podem ser alcançadas com o auxílio da automação dos processos de fabricação. Mas para que se tenha um processo totalmente automatizado, é fundamental o uso de sistemas de monitoramento, supervisão e diagnóstico<sup>1</sup> de máquinas, que possibilitem o estabelecimento de critérios confiáveis na determinação do momento mais apropriado para a troca da ferramenta [1].

O operador experiente geralmente adquire a habilidade de antecipar o momento da quebra da ferramenta. Ele associa a proximidade da quebra com a formação de faíscas na peça, com a alteração da forma do cavaco, com o acabamento da superfície usinada e com o ruído. Na verdade, o operador supervisiona os efeitos do processo através dos sentidos: visão, tato e audição.

Em outras palavras, durante o processo de usinagem, a deformação plástica e o atrito entre o cavaco, a ferramenta de corte e a peça produzem oscilações na força de usinagem. Estas oscilações produzem vibrações, tanto de alta frequência quanto de baixa. Com o decorrer do tempo de usinagem e com o conseqüente desgaste da ferramenta, os sinais de vibração apresentam alterações de amplitude e frequência. Por outro lado, as amplitudes das componentes ortogonais da força de usinagem também variam com o tempo de corte.

---

<sup>1</sup> O **monitoramento** envolve uma tarefa contínua (em tempo real) de determinação das condições de um sistema físico através do armazenamento de informações, reconhecimento de anomalias e identificação de problemas. A **supervisão** refere-se ao monitoramento de um sistema físico e a tomada de ações apropriadas, visando manter a ordem do sistema no caso de falhas. O **diagnóstico** tem a função de identificar o problema e suas possíveis causas. Esta função é frequentemente baseada em um ou vários modelos que descrevem a estrutura e/ou o comportamento do sistema em funcionamento (normal e/ou anormal) [197].

Portanto, um sistema que possibilite o estabelecimento de relações entre a variação das amplitudes e/ou frequências de vibração ou então as variações das amplitudes das componentes da força de usinagem com o desgaste da ferramenta podem ser úteis ao monitoramento da vida da ferramenta em tempo real.

Contudo, existe um grande esforço no sentido de desenvolver métodos para controlar o desgaste da ferramenta em sistemas de manufatura integrados e flexíveis.

Em geral, as estratégias utilizadas para determinar o momento de troca da ferramenta são baseadas em dados estatísticos. Mas o grau de complexidade e a característica imprevisível do processo de usinagem fazem com que a dispersão da vida da ferramenta seja muito grande. KLUFT [2] afirma em seu trabalho que em aplicações industriais, esta dispersão pode chegar a 330%. Portanto, muitas ferramentas são trocadas ainda em condições de serem utilizadas, acarretando um aumento do consumo de ferramentas e maiores tempos de parada de máquinas.

Segundo um estudo feito pela SANDVIK COROMANT, um aumento de 50% na vida da ferramenta reduz em determinados casos apenas 1% o custo do produto final. Já uma otimização de 20% nas condições de usinagem reduz em 15% este custo<sup>2</sup>. Assim, ferramentas de alto desempenho têm sido cada vez mais aplicadas com o intuito de suportar condições extremas de usinagem na busca da alta produtividade.

VARMA E KLINE [3] mostraram que o inserto agrega baixo custo no produto final. Já a ocorrência de uma colisão severa (mesmo acontecendo raramente) agrega altíssimo custo ao processo, além do risco de se perder a precisão e a exatidão<sup>3</sup> da máquina - muitas vezes de forma irreversível (evento imprevisível). Então, a aplicação de sistemas de monitoramento passa a ser imprescindível em sistemas automatizados.

Usualmente, há quatro áreas de interesse em monitoramento na usinagem: supervisão do estado da ferramenta, controle do processo de corte, inspeção da qualidade final da peça e integridade da máquina-ferramenta. Dentre estas, as falhas na ferramenta de corte, provocadas por avarias ou desgastes, afetam a qualidade do produto direta e significativamente. Assim, a detecção *on-line* da fratura, que sempre ocorre inesperadamente e pode provocar danos irreversíveis na peça ou até na máquina-ferramenta, é crucial para a auto-

---

<sup>2</sup> Extraído do texto **Teoria da Produtividade no Torneamento** no site <http://www.coromant.sandvik.com/br>.

<sup>3</sup> Segundo o "Vocabulário Internacional de Metrologia", **Precisão** (ou Repetitividade) significa a aptidão de um instrumento fornecer indicações muito próximas, quando se mede o mesmo mensurando, sob as mesmas condições. Está relacionada com as incertezas aleatórias da medição e com a qualidade do instrumento. **Exatidão** (ou Tendência) é a aptidão de um instrumento para dar respostas próximas ao valor verdadeiro do mensurando. A exatidão está relacionada com as incertezas sistemáticas da medição e com a calibração do instrumento [189].



mação de processos. Busca-se, portanto, uma forma de se determinar o momento que antecede tal fratura através do diagnóstico de falhas na ferramenta de corte, de modo a minimizar os problemas subsequentes.

Existem muitas técnicas de monitoramento do estado da ferramenta de corte (do inglês TCM – *Tool Condition Monitoring*), diretas e indiretas, que têm sido propostas e avaliadas nas últimas décadas [4–12]. As primeiras interrompem o processo e então quantificam as falhas diretamente na ferramenta através da medição com instrumentos apropriados. As segundas supervisionam um sinal indireto mensurável em tempo real, correlacionando um ou mais fenômenos físicos com o estado da ferramenta.

As tentativas que têm sido feitas para o desenvolvimento de sistemas TCM sem a interrupção da operação de usinagem consistem, basicamente, no estabelecimento de relações entre os parâmetros (variáveis dependentes) do processo e a situação da ferramenta. O trabalho de JEMIELNIAK [13] destaca a aplicação comercial de sensores ópticos (câmera e LASER<sup>4</sup>) na medição direta de desgastes e avarias, e os sensores de potência, torque, tensão, deslocamento, força, vibração (até 20 kHz), ultra-som (20 a 100 kHz) e emissão acústica (100 a 1000 kHz) na medição indireta. Todos possuem vantagens e limitações, levando-se em conta as características requeridas como confiabilidade, custo, repetitividade em ambientes reais e insensibilidade a fatores externos. Entretanto, nenhuma técnica tem provado ser completamente fidedigna sobre a extensa faixa de condições operacionais.

Em métodos TCM indiretos (*on-line*), a extração das informações de um único sinal sensorio raramente é sensível aos parâmetros que estabelecem a determinação do fim de vida de uma ferramenta numa extensa faixa de condições de usinagem [14; 15]. Isto mostra que quando a ferramenta atinge seu fim de vida conforme tais critérios, as características do sinal mensurado não são capazes de refletir de forma confiável o estado atual da mesma. Uma das principais razões é que os mecanismos de desgaste (fatores de origem térmica, mecânica, química e abrasiva) apresentam uma relação complexa com as propriedades dos materiais da ferramenta e da peça, assim como com as variações nas condições de corte [16–22]. Assim, fica muito complicado para uma característica, extraída de um único sensor, representar esta relação. Como consequência, a fusão de múltiplos sensores foi introduzida para o monitoramento de avarias e desgastes em ferramentas de corte [14;15;23–26]. O mais vantajoso aspecto talvez seja que esta integração proporcione um maior número de avaliações das informações presentes através de metodologias de processamento de sinais,

---

<sup>4</sup> A sigla LASER significa amplificação de luz por emissão estimulada de irradiação (do inglês *Light Amplification by Stimulated Emission of Radiation*). Representa um feixe luminoso de irradiação altamente concentrada, direcional e monocromático.

extração de características e tomada de decisão [14;15;27–29]. Contudo, o número de sensores necessários para diagnosticar o estado atual da ferramenta cresce linearmente, enquanto que a complexidade das relações entre as múltiplas características e as falhas na ferramenta cresce exponencialmente até um ponto intratável [23]. Além disso, a resposta dos sinais sensórios à vida da ferramenta não pode ser definida claramente, devido aos inúmeros fatores inerentes ao processo. Isto leva a crer que uma estimativa da vida da mesma não pode ser 100% confiável.

## 1.1 Objetivos

Baseando-se nas técnicas de aquisição e processamento de sinais, e na aplicação da inteligência computacional em processos de usinagem, este trabalho tem por objetivo apresentar uma proposta para supervisionar e diagnosticar o estado da ferramenta de corte em metais ao longo de sua vida num torno com comando numérico com a mínima participação humana, em que se pretende expor a viabilidade da aplicação de um sistema de monitoramento inteligente na determinação do momento mais adequado para a troca da ferramenta.

As justificativas para tal implementação são descritas no item subsequente.

## 1.2 Justificativas para a Implementação

Quatro considerações importantes podem justificar o estudo de sistemas TCM:

- ☑ Com a utilização, o gume da ferramenta vai perdendo a sua capacidade de corte à medida que vai se desgastando. Este aumento progressivo do desgaste faz com que a ferramenta de corte passe a não suportar mais a força de usinagem, podendo resultar em falhas catastróficas na ferramenta (quebra do gume). O gradiente de desgaste não é a principal preocupação em operações de corte, mas sim fatores como acabamentos e tolerâncias da peça usinada e vibrações da máquina-ferramenta. Tais fatores são afetados pela magnitude da marca de desgaste presente no gume da ferramenta, e não pelo gradiente de desgaste.
- ☑ Valores máximos de desgaste (muitas vezes subjetivos) são definidos no gume da ferramenta a partir das tolerâncias máxima e mínima permitidas à peça usinada. Se um valor de desgaste for desconsiderado ou alterado, poder-se-á ter como consequência a

rejeição da peça durante a avaliação pelo controle de qualidade. Em outros casos, uma insatisfação do cliente como resultado de uma peça com tamanho menor ou maior. No chão-de-fábrica, níveis inaceitáveis de desgaste nas ferramentas de corte, em níveis excessivos de vibração na máquina-ferramenta, podem ser prejudiciais ao *set-up*<sup>5</sup> desta.

- ☑ Os principais aspectos e ocorrências dos desgastes em ferramentas estão geralmente associados à danificação casual do subsistema ferramenta-peça. A maioria dos estudos em desgastes de ferramentas preocupa-se com os desgastes e avarias na quina, no flanco (superfície de incidência) e na face (superfície de saída). Diferentes mecanismos são considerados como responsáveis por tais danos, destacando-se as falhas mecânicas (abrasão), as falhas térmicas (difusão, oxidação e deformação plástica) e a aderência.
- ☑ Atualmente, a busca pelos altos índices de produtividade tem conduzido a maioria das empresas a adotar sistemas de manufatura integrados e flexíveis (CIM – *Computer-Integrated Manufacturing* e FMS – *Flexible Manufacturing System*), nos quais se busca a produção variada de lotes reduzidos. Logicamente, tais sistemas dispõem de uma alta taxa de automação em chão-de-fábrica, e a aplicação de sistemas TCM passa a ser inevitável. Logo, a medição cautelosa que busca reconhecer as falhas e substituir a ferramenta deteriorada de maneira eficiente torna-se necessária. Estas falhas podem gerar vibrações inconvenientes na máquina. Uma possível consequência destas falhas poderia ser a fratura da ferramenta (quebra do gume, primeiro item), causando com isso uma sobrecarga de potência e danos na máquina, assim como prejuízos na peça. Os altos custos envolvidos nestas perdas sugerem que a limitação ou a prevenção desta falha catastrófica seja preponderante. Daí a importância de se definir um critério para a determinação do fim de vida da ferramenta de corte buscando a redução de desperdícios.

### 1.3 Originalidade

Pela revisão da literatura, foi possível observar que, na maioria dos trabalhos (em cerca de 85%), constatou-se que os principais objetivos do sistema de monitoramento do estado da ferramenta de corte estão focados na classificação e na estimativa *on-line* dos desgastes. Uma outra parcela (aproximadamente 10%) preocupa-se com a classificação das fraturas – em geral, quebrada e não-quebrada. O restante (perto de 5%) busca outras pos-

---

<sup>5</sup> O tempo de *set-up* corresponde em fabricação ao tempo de preparação de máquinas e ferramentas.

sibilidades (e.g. detecção da vibração auto-excitada, da forma do cavaco, da rugosidade da peça). A maior ênfase na classificação e/ou estimativa dos desgastes justifica-se pelo fato de que as informações adquiridas podem ser usadas para controlar a posição e o desgaste das ferramentas visando garantir, respectivamente, as especificações geométricas da peça e a qualidade da superfície usinada. A fratura também não deve ser ignorada, pois pode trazer danos irreversíveis à ferramenta e à peça; com isso, deve ser evitada ao máximo. Assim, a detecção de falhas, sejam elas desgastes ou avarias, é fundamental para o controle do estado da ferramenta de corte.

Dentre todos os trabalhos observados (referenciados ou complementares) na busca da estimativa do tempo restante da ferramenta de corte, foi possível encontrar apenas dois trabalhos (ainda sim nas referências citadas por Sick [12]). O primeiro, de 1995, calculou a largura da marca de desgaste de flanco e o comprimento de corte restante para um padrão "normal" de desgaste por meio de equações específicas (com base na equação de Taylor<sup>6</sup>) cujas variáveis eram as condições de corte. Infelizmente, o artigo não mostrou resultados experimentais para a determinação destas variáveis. O segundo, de 1998, apresentou objetivo similar: buscou estimar o percentual de vida restante da ferramenta. Esta carência serviu de incentivo para o desenvolvimento de um trabalho que pudesse se destacar pela sua originalidade em prognosticar o tempo de vida restante com base no diagnóstico de falhas da ferramenta de corte em torneamento.

## 1.4 Contribuições

Almeja-se que os resultados do presente trabalho contribuam direta ou indiretamente para uma melhor compreensão das técnicas de monitoramento e controle da ferramenta de corte em torneamento de desbaste leve ou semi-acabamento. Os conceitos e as metodologias sobre monitoramento e reconhecimento de falhas da ferramenta via sinais sensórios indiretos poderão servir de base para o entendimento dos fundamentos acerca do tema.

A partir das relações estabelecidas entre a variação dos sinais sensórios (força, vibração e emissão acústica) monitorados e as falhas da ferramenta (desgaste e avarias), pode-se formar a base de conhecimento do sistema, determinando assim os índices de monitoramento através de uma metodologia apropriada e devidamente descrita. De modo a poder verificar apenas a relação entre as características extraídas dos sinais e o estado da ferra-

---

<sup>6</sup> A equação de Taylor é definida por:  $v_c \times T^n = C$ , onde " $v_c$ " é a velocidade de corte, " $T$ " é o tempo de vida e as variáveis " $n$ " e " $C$ " dependem do material usinado e da ferramenta aplicada [22; 31].

menta, as variáveis independentes de entrada do processo devem ser definidas e mantidas constantes, para que as correlações entre as variáveis dependentes de saída possam ser apropriadamente avaliadas.

Pretende-se assim contribuir com o desenvolvimento e a implementação de um “sistema inteligente” que seja capaz de **estimar**, a partir da combinação dos índices de monitoramento via redes neurais artificiais, o valor da largura média da marca de desgaste de flanco ( $VB_B$ ) da ferramenta de corte. As definições de redes neurais e suas aplicações na decisão ou tomada de decisão sobre o estado da ferramenta poderão colaborar na escolha da arquitetura mais apropriada para um sistema inteligente de monitoramento. A partir de índices apropriados, o sistema será também capaz de **detectar** o momento que ocorre a fratura (lascamentos e/ou quebra). Com as informações estimadas ( $VB$ ) e detectadas, o sistema proverá o **diagnóstico on-line** do estado da ferramenta.

Como resultado, o sistema propõe-se a estimar, a partir de um **prognóstico** (com base no **diagnóstico on-line**), o tempo de vida que ainda resta à ferramenta de corte (lembrando que as variáveis de entrada foram mantidas constantes). Esta solução poderá proporcionar uma maior confiabilidade ao processo de torneamento, minimizando ou até eliminando o efeito da falha da ferramenta na peça usinada.

## 1.5 Estrutura do Trabalho

De forma a: (a) elucidar as técnicas de aquisição e processamento de sinais de força, vibração e emissão acústica no monitoramento indireto do estado da ferramenta de corte; (b) mostrar a importância das técnicas de inteligência computacional (principalmente redes neurais artificiais) na classificação e estimativa de desgastes de ferramentas em torneamento; e (c) expor o desenvolvimento, a implementação, os resultados e as conclusões deste trabalho, ele foi dividido em 13 (treze) partes abaixo sumariadas:

- ☑ **Capítulo 1 – Introdução:** descrição sucinta da proposta de trabalho, mostrando a ideia geral e as diferentes abordagens do tema em discussão – aplicação de múltiplos sensores no diagnóstico de falhas e prognóstico da vida da ferramenta.
- ☑ **Capítulo 2 – Usinagem e Torneamento:** exposição teórica das definições sobre variáveis independentes de entrada (e.g. parâmetros de corte) e variáveis dependentes de saída (e.g. falhas na ferramenta) envolvidas no processo de torneamento.

- ☑ **Capítulo 3 – Vida da Ferramenta:** fundamentos sobre os mecanismos de desgaste, os desgastes e avarias gerados na ferramenta, e também os critérios para o estabelecimento do fim de vida de uma ferramenta de corte em torneamento.
- ☑ **Capítulo 4 – Formulação do Problema:** descrição sucinta dos principais problemas enfrentados nas operações de torneamento, relacionados com a supervisão automática da máquina e do processo. Também, as capacidades necessárias a um sistema de monitoramento: responder imediatamente a uma colisão; estimar ou classificar desgastes; identificar avarias.
- ☑ **Capítulo 5 – Monitoramento do Estado da Ferramenta de Corte:** revisão da literatura sobre os conceitos e metodologias do monitoramento inteligente (sensoriamento; condicionamento de sinais; tratamento de sinais e extração de características; reação e tomada de decisão) de ferramentas de corte em torneamento.
- ☑ **Capítulo 6 – Reconhecimento da Falha via Sinais Indiretos:** levantamento das principais características e aplicações de sinais sensórios – força; vibração; emissão acústica – no monitoramento indireto (*on-line*) da ferramenta de corte em torneamento.
- ☑ **Capítulo 7 – Redes Neurais Artificiais:** descrição dos fundamentos de redes neurais artificiais (estrutura; topologia; treinamento; estimativa, classificação, ou identificação) e suas aplicações em sistemas TCM inteligentes.
- ☑ **Capítulo 8 – Formação da Base de Conhecimento:** testes preliminares realizados para analisar o comportamento dos sinais sensórios (força, vibração e emissão acústica) em ensaios de torneamento, utilizando diferentes técnicas de aquisição e processamento de sinais, com o intuito de extrair suas características e assim determinar os índices de monitoramento mais adequados ao reconhecimento de padrões de falha da ferramenta de corte para o sistema monitor inteligente.
- ☑ **Capítulo 9 – Proposta de um Sistema Monitor Inteligente:** exposição do sistema TCM inteligente, justificando as escolhas das técnicas de aquisição, processamento e tomada de decisão, com base no conhecimento adquirido sobre o processo de reconhecimento de padrões de falha da ferramenta de corte via análise de sinais sensórios (força, vibração e emissão acústica).
- ☑ **Capítulo 10 – Implementação do Sistema Monitor:** desenvolvimento da proposta na implementação de um sistema monitor inteligente que efetua o monitoramento indi-

reto da ferramenta de corte, o diagnóstico das falhas detectadas, e o prognóstico da vida restante.

- ☑ **Capítulo 11 – Conclusões e Perspectivas:** considerações finais baseadas no trabalho desenvolvido: (a) estabilidade e capacidade do sistema monitor inteligente; (b) limitações do sistema; (c) tendências e direções; (d) propostas para trabalhos futuros.
- ☑ **Capítulo 12 – Referências:** bibliografias usadas na elaboração deste trabalho, citadas em partes do texto ou apenas consultadas para a obtenção de dados adicionais.
- ☑ **Anexos:** suportes esclarecedores relativos ao conteúdo do trabalho: (a) a calibração do dinamômetro piezelétrico para aquisição de sinais de força; (b) valores de força, vibração, rugosidade e tempo de vida da ferramenta para diferentes parâmetros de corte; (c) variações percentuais do sinal de força; (d) tabelas dos resultados finais obtidos nos experimentos de comprovação.

A seguir (Capítulo 2), far-se-á uma breve descrição das diferentes variáveis de entrada (independentes) e saída (dependentes), envolvidas no **Processo de Torneamento**.

## 2 - FUNDAMENTOS DO PROCESSO DE TORNEAMENTO



*“O processo de torneamento envolve um grande número de variáveis que podem influir no desempenho de uma operação específica. Basta o desvio de uma única variável para comprometer todo o processo”.*

DAVID A. DORNFELD

**Usinagem** é um termo genérico designado para descrever o processo de remoção de material de uma peça, conferindo-lhe forma, dimensão, acabamento, ou uma combinação qualquer destes três itens. Na maioria das aplicações industriais, a usinagem é usada para converter blocos (tarugos) metálicos fundidos, forjados ou pré-moldados em perfis desejados, com tamanho e acabamento específicos, de acordo com as necessidades do projeto. Quase todos os produtos manufaturados possuem componentes que precisam ser usinados, muitas vezes com grande precisão. Logo, este conjunto de processos é um dos mais importantes do sistema de manufatura, pois agrega valor ao produto final [30; 31].

A usinagem pode ser dividida em duas grandes categorias [32]: **processos convencionais** e **processos não-convencionais**. Na primeira, as operações de corte empregam energia mecânica na remoção do material, principalmente por cisalhamento, no contato físico da ferramenta com a peça. Na segunda, as operações utilizam-se de outros tipos de energia de usinagem (e.g. termelétrica), não geram marcas-padrão na superfície da peça e a taxa volumétrica de remoção de material é muito menor que a dos processos convencionais – ex: laser (radiação), eletroerosão (elétrons) e plasma (gases quentes).

Os processos convencionais de usinagem em metais ainda podem ser subdivididos em duas classes: (a) operações de corte com **ferramentas de geometria definida** (gumes com formato e tamanho conhecidos) – e.g. torneamento, furação, fresamento; e (b) operações de corte com **ferramentas de geometria não-definida** (gumes minúsculos de partículas abrasivas com formatos aleatórios) – e.g. retificação, brunimento, lapidação.

O **torneamento** é um tipo de processo convencional de usinagem que utiliza ferramentas com geometria definida. FERRARESI [31] define **torneamento** como sendo um processo mecânico de usinagem destinado à obtenção de superfícies de revolução com auxí-



lio de uma ou mais ferramentas monocortantes. Para tanto, a peça gira em torno do eixo principal de rotação da máquina e a ferramenta se desloca simultaneamente segundo uma trajetória coplanar (retilínea ou curvilínea) com o referido eixo. A figura 2.1 mostra alguns dos principais tipos de operações de torneamento.




Figura 2.1 – Operações de torneamento [32]

Quanto à finalidade, as operações de torneamento podem ser classificadas ainda em operação de desbaste e operação de acabamento. Entende-se por **acabamento** a operação de usinagem destinada a obter na peça as dimensões finais, ou um acabamento especificado, ou ambos. O **desbaste** é a operação de usinagem, anterior a de acabamento, visando obter na peça a forma e dimensões próximas das finais [31].

## 2.1 Variáveis Envolvidas no Processo

Dentre as variáveis envolvidas no processo de corte com formação de cavaco, existem aquelas nas quais se pode intervir (variáveis independentes de entrada) e aquelas nas quais não se pode (variáveis dependentes de saída), já que sofrem influência da mudança nas variáveis de entrada [32; 33].

Uma maneira de controlar o processo de usinagem é atuar diretamente nas variáveis de entrada (independentes) e mensurar seu efeito através da medida de variáveis dependentes de saída. As condições ideais para um determinado processo de usinagem podem ser determinadas com um melhor aproveitamento da ferramenta de corte e uma melhor taxa de remoção de material. A figura 2.2 resume as relações entrada/saída associadas com o processo de torneamento.

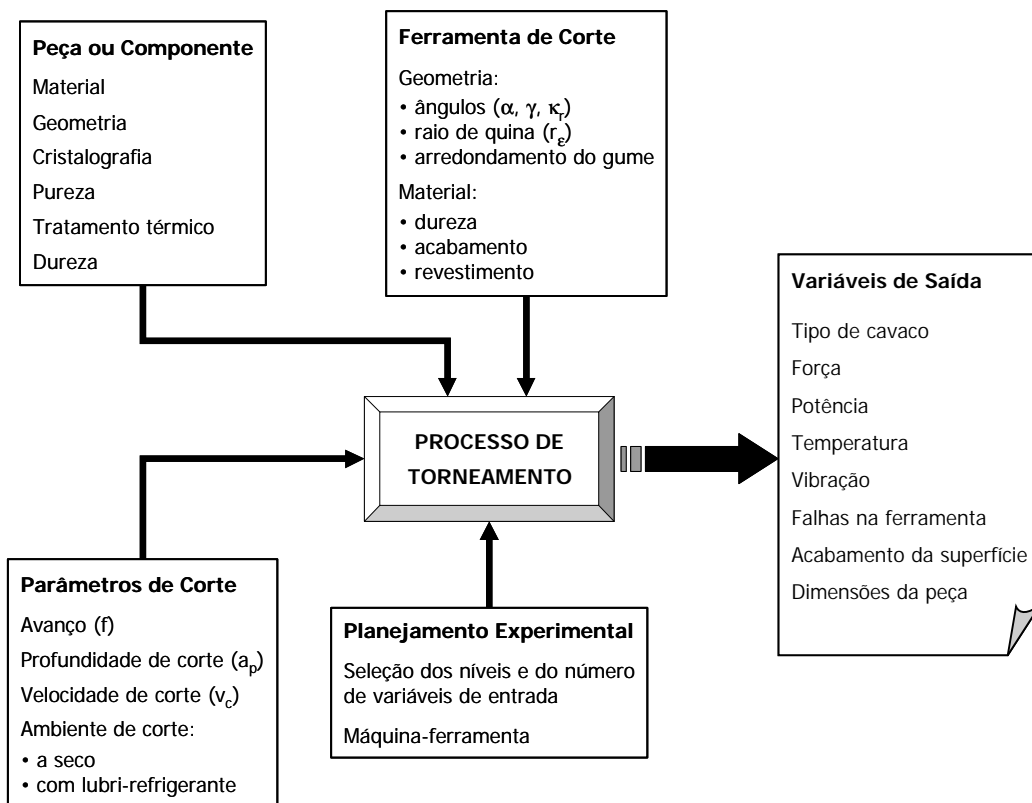


Figura 2.2 – Relações de entrada e saída em torneamento [33]

As características extraídas dos sinais de força, vibração e emissão acústica geradas no processo podem ser consideradas variáveis dependentes, uma vez que sofrem modificações com o tipo de operação, condições de usinagem, materiais e estado da ferramenta. Maiores detalhes serão discutidos no Capítulo 6.

### 2.1.1 Variáveis Independentes de Entrada

#### (a) Material da peça

As propriedades físicas, químicas e mecânicas do material da peça bruta (dureza, resistência à tração, composição química, inclusões, afinidade química com o meio lubrificante ou com a ferramenta, microestrutura, encruamento etc.) podem ser especificadas ou previamente conhecidas. Algumas vezes, um material é selecionado para uma aplicação em particular, simplesmente porque pode ser trabalhado com certa facilidade (como é o caso de algumas ligas de ferro fundido e alumínio). Materiais tais como aço inoxidável ou titânio já são de difícil usinabilidade<sup>7</sup>, pois podem gerar desgaste rápido da ferramenta, necessidade de elevadas forças ou potências de corte, acabamento superficial de baixa qualidade etc. Tais problemas podem resultar numa redução de tempo de vida da ferramenta de corte, ainda que estes materiais possam ser selecionados para satisfazer critérios funcionais importantes de projeto [34].

#### (b) Geometria da peça

A geometria de uma peça (tamanho e forma) pode ser gerada através de processos anteriores, ou pode ser selecionada a partir da matéria-prima padrão para usinagem. Geralmente estas variáveis influenciam diretamente no processo de usinagem ou nos parâmetros que são selecionados, como por exemplo, a profundidade de corte. Peças assimiláveis a sólidos de revolução (eixos, engrenagens, polias, tampas) são as que podem ser submetidas às operações de desbaste e acabamento em torneamento. Os fatores que devem ser considerados na escolha entre uma peça forjada ou de barra na confecção destes elementos de máquinas são: o cálculo dimensional; o sobremetal a ser removido; a disponibilidade da máquina-ferramenta [34].

---

<sup>7</sup> A **usinabilidade** de um material é definida como uma grandeza tecnológica que expressa, por meio de um valor numérico comparativo (índice de usinabilidade), um conjunto de propriedades (que influem sobre: a vida da ferramenta, os esforços de corte, o acabamento da superfície usinada, a temperatura de corte, a produtividade e as características do cavaco) em relação a outro material tomado como padrão. Em outras palavras, a usinabilidade expressa o grau de dificuldade de se usinar um determinado material [22; 31]. A usinabilidade é uma propriedade que depende da interação entre o processo de fabricação e as características do material da peça.

### (c) Material da ferramenta

A seleção do material da ferramenta que produza o desempenho desejável nas condições requeridas de processo – que dependem do material que será usinado, dos parâmetros de corte e das características da máquina-ferramenta – ainda é um desafio, já que nenhum material possui as propriedades a serem exigidas da ferramenta no seu mais alto grau (dureza e resistência à compressão; dureza a quente; tenacidade e resistência à flexão; resistência à abrasão; e estabilidade química) [21].

Os dois tipos de materiais mais comuns usados em ferramentas de corte destinadas às operações tradicionais de usinagem são: **metal-duro** e o **aço-rápido** (HSS – *high-speed steel*), que juntos somam 90% das aplicações na indústria moderna. Outros materiais mais avançados, tais como: nitreto de boro cúbico (CBN – *cubic boron nitride*), cerâmica e diamantes, detêm 10% das aplicações [35].

O **metal-duro** é usado em cerca de 50% das aplicações devido ao custo e à combinação da dureza à temperatura ambiente, dureza a quente, resistência ao desgaste e tenacidade, possível graças à variação da sua composição. A ferramenta de metal-duro pode ser aplicada em altas velocidades de corte [35]. O **aço-rápido** é usado em ferramentas de uso geral [usinagem de peças forjadas, fundidas ou sinterizadas (metalurgia do pó)], em ferramentas de geometria complexa ou naquelas usadas em situações em que as velocidades de corte são mais modestas. Principais propriedades: dureza a quente, resistência ao desgaste e tenacidade [21]. Cerca de 40% das ferramentas aplicadas na indústria são de HSS [35]. Os **revestimentos** tais como nitreto e carboneto de titânio (TiN e TiC) são comumente aplicados em ferramentas de aço-rápido e metal-duro com o objetivo de aumentar o tempo de vida.

### (d) Geometria da ferramenta

A ferramenta de corte é geralmente designada para realizar uma operação específica de usinagem, e a geometria (ângulos) desta ferramenta deve ser devidamente escolhida para poder executá-la com precisão. A formação de cavacos, a saída dos cavacos, as componentes da força de usinagem e o desgaste da ferramenta são consideravelmente influenciados pela geometria da ferramenta.

A tabela 2.1 mostra alguns valores teóricos de como as componentes da força de usinagem variam quando o ângulo de saída ( $\gamma$ ) e/ou de inclinação ( $\lambda$ ) variam. Uma alteração do ângulo de folga ( $\alpha$ ) na faixa de  $3^\circ$  a  $12^\circ$  não tem nenhum efeito evidente sobre as componentes da força de usinagem. Da mesma forma, uma alteração do raio de quina ( $r_e$ ) não

exerce nenhuma influência significativa sobre as forças, enquanto for obedecida a exigência:  $a_p \geq 2 \cdot r_\epsilon$  [19]. Vale salientar que quanto maiores os ângulos de saída (principalmente) e de inclinação, menores serão a deformação e o trabalho de separação do cavaco da peça e, por conseguinte, menores serão: a temperatura, a pressão específica de corte e o desgaste da ferramenta. Porém, com o aumento do ângulo " $\gamma$ ", a resistência da cunha da ferramenta diminui e a sua sensibilidade aos choques aumenta. Assim, recomenda-se o uso de ângulos " $\gamma$ " negativos para fortalecer o gume – principalmente na usinagem de materiais frágeis (com formação de cavacos curtos). Somente na usinagem de materiais dúcteis (com formação de cavacos longos) em que baixas forças de corte são necessárias, é que se recorre aos ângulos " $\gamma$ " positivos [22; 31].

**Tabela 2.1** – Influência dos ângulos de saída e folga nas componentes das forças de usinagem [19]

MUDANÇA NAS COMPONENTES DA FORÇA DE USINAGEM PARA CADA GRAU DE ÂNGULO ALTERADO				
Fatores de influência		Força de Avanço ( $F_f$ )	Força Passiva ( $F_p$ )	Força de Corte ( $F_c$ )
AUMENTO $\triangle$	Ângulo de saída ( $\gamma$ )	$\triangle$ 5,0%	$\triangle$ 4,0%	$\triangle$ 1,5%
	Ângulo de inclinação ( $\lambda$ )	$\triangle$ 1,5%	$\triangle$ 10%	$\triangle$ 1,5%
DIMINUIÇÃO $\blacktriangledown$	Ângulo de saída ( $\gamma$ )	$\blacktriangledown$ 5,0%	$\blacktriangledown$ 4,0%	$\blacktriangledown$ 1,5%
	Ângulo de inclinação ( $\lambda$ )	$\blacktriangledown$ 1,5%	$\blacktriangledown$ 10%	$\blacktriangledown$ 1,5%

A substituição de um ângulo de saída positivo por um negativo, nas mesmas condições de usinagem, exige uma potência de corte maior. Uma vez que esta potência é transformada em calor, o ângulo " $\gamma$ " negativo acarreta um aumento da temperatura no gume. Esta é uma das razões por que o ângulo " $\gamma$ " negativo é empregado somente na usinagem com pastilhas de metal-duro e de cerâmica [31].

### (e) Parâmetros de corte

Para cada operação de usinagem é necessário decidir quais serão os parâmetros de corte utilizados [velocidade de corte ( $v_c$ ), avanço ( $f$ ) e profundidade de corte ( $a_p$ )]. Muitos fatores vão de encontro a tais decisões, pois todas as variáveis dependentes são influenciadas por elas. A seleção apropriada destes parâmetros depende também de outras variáveis de entrada que devem ser escolhidas com antecedência: a quantidade total de material a ser removido; os materiais da peça e da ferramenta; e a(s) operação(ões) de corte envolvi-

das [17; 18]. Em geral, operações de desbaste envolvem baixas velocidades de corte, altos avanços e altas profundidades de corte; já operações de acabamento trabalham com baixos avanços, baixas profundidades de corte e altas velocidades de corte.

### (f) Meios lubri-refrigerantes

A seleção correta do meio lubri-refrigerante (também chamado fluido de corte, óleo de corte, meio de lubrificação e arrefecimento, líquido refrigerante etc.) para uma combinação particular peça-ferramenta pode significar a diferença entre o sucesso e o fracasso em quase todos os processos de usinagem. A lubrificação e a refrigeração têm por finalidade: aumentar a vida da ferramenta; aumentar a eficiência da remoção do cavaco da região de corte; melhorar o acabamento da superfície usinada; reduzir a força e potência de corte [21; 31]. Por outro lado, a usinagem a seco está crescendo na indústria de corte de metais. Na usinagem a seco, não se verificam as funções primárias dos fluidos de corte: refrigeração, lubrificação e transporte de cavacos. Assim, exige-se uma adaptação compatível de todos os fatores influentes: máquina, peça, ferramenta, processo e parâmetros de corte.

Modernas ferramentas de corte têm sido desenvolvidas para suportar altas temperaturas na região de corte, sem perder a dureza e a resistência ao desgaste. Com isso, é possível se aumentar a produtividade com a usinagem a seco, pois não se elimina apenas o custo com o lubrificante-refrigerante, mas também o tempo e o custo com a manutenção. Além dos aspectos tecnológicos e econômicos citados, os aspectos ecológicos também merecem destaque (os fluidos de corte são nocivos ao homem e agredem o meio ambiente) [19; 36].

### (g) Máquina-ferramenta

Para o desempenho das diferentes operações de torneamento, existe uma grande variedade de tornos que podem ter diferentes configurações: convencional, revólver, copiador, automático, com comando numérico etc. As operações podem ser combinadas em máquinas-ferramenta com múltiplas capacidades, chamadas de centros de torneamento. Os centros de torneamento são máquinas numericamente controladas capazes de efetuar operações simultâneas em diferentes direções da peça, e.g. sangramento e faceamento [32].

## 2.1.2 Variáveis Dependentes

As variáveis dependentes de saída são determinadas pelo processo, baseando-se na prévia seleção das variáveis independentes de entrada. Desta forma, a pessoa responsável

pelo controle da produção trabalha na supervisão destas variáveis, usualmente indiretas. As variáveis dependentes de saída importantes são: tipo de cavaco; força e potência de corte; temperatura na região de corte; vida da ferramenta (desgastes e avarias); acabamento da superfície usinada; tamanho e propriedades finais da peça ou componente etc. [33].

### (a) Tipos de cavacos

Observando os tipos de cavacos formados em torneamento, verifica-se que os mesmos podem apresentar aspectos distintos, dependendo das variáveis independentes de entrada. A figura 2.3 mostra os quatro principais tipos de cavaco.


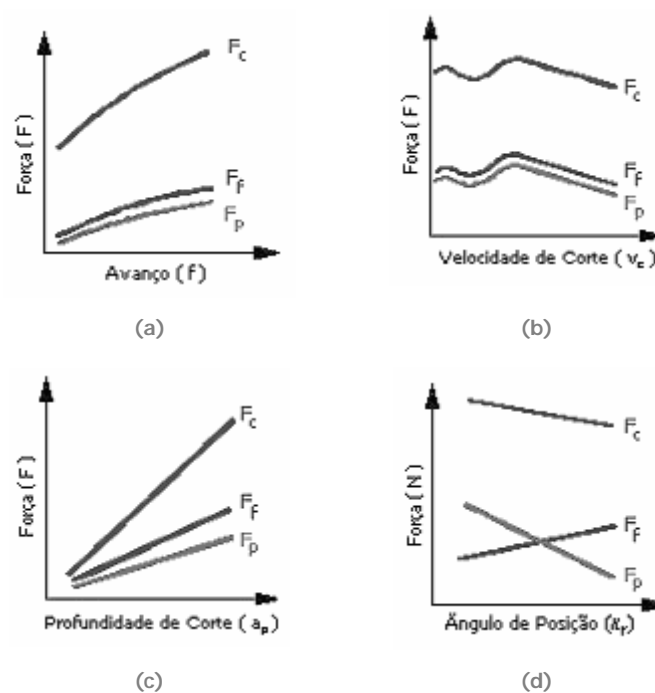


Figura 2.3 – Principais tipos de cavaco [19]

O tipo **contínuo** é o mais desejável do ponto de vista de acabamento da peça, durabilidade da ferramenta e energia consumida, pois ele desliza suave e uniformemente sobre a face (superfície de saída) da ferramenta. O cavaco é removido com ajuda de quebra-cavacos e sua formação é favorecida pela utilização de: ângulo de saída grande, avanço pequeno (pequena espessura de cavaco), velocidade de corte alta, ferramenta afiada, meio lubri-refrigerante eficiente e máquina rígida [21]. Cavacos do tipo **lamelar** ocorrem quando a estrutura do material é irregular ou quando vibrações (geradas por grandes avanços e/ou altas velocidades de corte) levam a variações na espessura do cavaco. No tipo **cisalhado**, a formação do cavaco é descontínua, pois a força de corte cresce progressivamente com a deformação do material até seu rompimento e fragmentação, quando então a força cai bruscamente e o gume reinicia o processo de deformação, repetindo-se o ciclo. A qualidade da superfície usinada passa a ser inferior e há uma tendência de se ter vibrações. Apresenta-se em geral como uma fita contínua, pois os efeitos da pressão e da temperatura soldam os fragmentos. O tipo **arrancado** é o cavaco que se produz na usinagem de materiais frágeis (e.g. ferro fundido e latão), tendo a forma de pequenos fragmentos independentes e distintos, gerados por ruptura (tensões de tração e compressão) [17; 18; 21].

## (b) Força e potência de usinagem

A usinagem de um metal usando parâmetros de corte ( $v_c$ ,  $f$ ,  $a_p$ ) definidos, meio lubri-refrigerante específico e ferramenta de corte determinada (material e geometria), gera forças, energia e potência de usinagem. Uma mudança em qualquer uma das variáveis de entrada altera os valores das forças. Assim, se for necessário modificar tais valores, deverá alterar os parâmetros que geram estas forças [33]. A figura 2.4 apresenta qualitativamente a dependência das componentes da força de usinagem em função dos parâmetros de corte ( $v_c$ ,  $f$ ,  $a_p$ ) e do ângulo de posição ( $\chi_r$ ).



**Figura 2.4** – Dependência das componentes das forças de usinagem em relação a: (a) avanço; (b) velocidade de corte; (c) profundidade de corte; (d) ângulo de posição [19]

A ação do ângulo de posição ( $\chi_r$ ) sobre as forças de avanço ( $F_f$ ) e passiva ( $F_p$ ) ocorre devido à localização geométrica do gume principal com relação ao eixo da peça, já que com maiores valores de " $\chi_r$ " a componente da força de usinagem aumenta na direção de avanço ( $F_f$ ) e têm seu máximo quando  $\chi_r = 90^\circ$ . Se este ângulo for aumentado, a espessura do cavaco ( $h$ ) aumenta na mesma proporção que a largura do cavaco ( $b$ ) diminui. Já que a força de corte ( $F_c$ ) é proporcional à profundidade de corte ( $a_p$ ) (equivalente a " $b$ "), ela aumenta de forma inversamente proporcional ao avanço (equivalente a " $h$ "), resultando das duas variações uma pequena redução de " $F_c$ " com aumento de " $\chi_r$ " [19].

Vale ressaltar que a área da seção transversal de corte ( $A$ ) vale:



$$A = a_p \cdot f = b \cdot h \quad [2.1]$$

e a relação entre o ângulo de posição e os parâmetros apresentados é:


$$\text{sen}(\chi_r) = \frac{a_p}{b} = \frac{h}{f} \quad [2.2]$$

As forças são importantes, pois influenciam as deflexões na ferramenta e na peça, afetando as dimensões finais do componente usinado. As forças também são responsáveis pelos fenômenos de vibração, comuns em usinagem [19]. Busca-se sempre uma forma de se controlar as forças geradas (e a potência consumida) para assim poder assegurar a integridade do sistema máquina-ferramenta-peça.

### (c) Temperatura na região de corte

Os trabalhos durante a usinagem provenientes: da deformação plástica do cavaco na região de cisalhamento, do atrito do cavaco com a face da ferramenta e do atrito da peça com o flanco da ferramenta, são transformados em calor. Conseqüentemente, a temperatura na região de corte se elevará, de acordo com o calor específico e a condutibilidade térmica dos materiais em contato, além das dimensões das seções onde se dissipa calor. Os efeitos de formação e transmissão de calor no corte de metais são muito complexos, pois o aumento da temperatura promove mudanças nas características físicas e mecânicas da peça. A temperatura influi diretamente no desgaste da ferramenta. Assim, a aplicação dos parâmetros de corte na busca da máxima produtividade e do maior tempo de vida para a ferramenta é limitada por este fator. Estudos sobre a formação e transmissão de calor na região de corte em função das diferentes condições de usinagem permitem determinar as ferramentas mais apropriadas para uma maior eficiência do processo [18; 37].

A representação na figura 2.5(a) informa as quantidades percentuais de calor absorvidas pela peça, cavaco e ferramenta. A maior parte do calor (75%) é transportado pelo cavaco. A parcela principal da energia mecânica é transformada na região de cisalhamento. As quantidades de calor das diversas regiões de transformação de energia são dissipadas por condução, irradiação e convecção para o meio ambiente. Como consequência desse balanço térmico têm-se campos de temperatura [fig. 2.5(b)] que se modificam até que haja equilíbrio entre a quantidade de calor gerada e a transmitida para fora.



**Figura 2.5** – Distribuição de (a) calor e (b) temperatura na interface peça-cavaco-ferramenta durante a usinagem de aço [19; 32]

#### (d) Vibrações

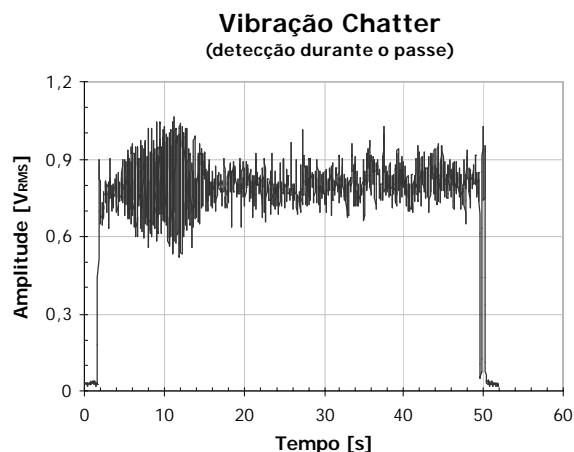
Oscilações das componentes ortogonais da força de usinagem (variações cíclicas das parcelas dinâmicas) geram movimentos periódicos na estrutura da máquina-ferramenta. Estas oscilações são chamadas de **vibrações mecânicas** [21]. Os sinais de vibração, resultantes do processo de corte em metais, podem ser basicamente forçados (causados por elementos mecânicos da máquina-ferramenta) ou auto-excitados<sup>8</sup> (gerados por interações do processo de usinagem com a estrutura da máquina-ferramenta).

A medição direta da vibração é difícil de ser efetuada, pois na determinação das características representativas do sinal, o modo de vibração depende da frequência. Por isso, parâmetros correlacionados, tais como variações da parcela dinâmica da força de usinagem por unidade de tempo (aceleração), são medidos, e características derivadas deste padrão são obtidas [11]. Uma das causas da vibração é o atrito entre a superfície usinada e o flanco da ferramenta: a tendência à vibração cresce com o aumento da largura da marca de desgaste (VB). A geometria da ferramenta também influi no comportamento de vibrações: raio de quina ( $r_\epsilon$ ) grande contribui para o seu crescimento. Com o aumento da vibração, a vida da ferramenta tende a diminuir com maior rapidez, pois microlascamentos são produzidos no gume. O acabamento superficial também sofre influência direta, diminuindo a qualidade da superfície usinada com o aumento da vibração [21].

A figura 2.6 mostra a detecção da vibração auto-excitada (*chatter*) durante uma operação de torneamento realizada nos ensaios preliminares deste trabalho. No caso, em

<sup>8</sup> A **vibração auto-excitada** é geralmente chamada de **vibração *chatter***. Esta vibração representa uma sequência de violentas oscilações causadas por intensas flutuações da força de usinagem [77].

condições severas de usinagem, a trepidação próxima dos 10 segundos ocorreu por causa do sistema de fixação da peça no torno: a ponta do contra-ponto encontrava-se estendida além do apropriado.



**Figura 2.6** – Vibração *chatter* detectada no torneamento a seco do aço ABNT 1040 usando inserto de metal-duro. Parâmetros:  $f = 0,3$  mm,  $v_c = 350$  m/min e  $a_p = 1,5$  mm

### (e) Falhas<sup>9</sup> na ferramenta de corte

Geralmente, a deformação plástica e o atrito inerentes ao processo geram altas temperaturas na região de corte (interface ferramenta-peça), fazendo com que a resistência ao desgaste da ferramenta diminua de maneira considerável. O problema é complexo, mas significativo. Como a ferramenta se desgasta, sua geometria e seu tamanho modificam-se. Um gume sem capacidade de corte e alterado geometricamente pode aumentar a força de usinagem, aumentando, por conseguinte, as deflexões na peça e podendo ainda gerar vibrações auto-excitadas. Já um aumento na potência consumida promove um acréscimo da temperatura na região de corte, acelerando o desgaste. Além disso, alterações dimensionais da ferramenta modificam a geometria da peça. Normalmente, tem-se um controle indireto destas variáveis, pois é possível selecionar velocidades de corte menores, que geram menos calor na região de corte e com isso um desgaste menor da ferramenta; infelizmente, a produtividade diminui, pois a taxa de remoção de material decresce. Alternativamente, a profundidade de corte e/ou o avanço podem ser aumentados para manter a taxa de remoção de material com baixas velocidades de corte; entretanto, um aumento da profundidade de corte ou do avanço promove um crescimento da força de usinagem. Desta forma, enquanto

---

<sup>9</sup> **Falha** pode ser definida como um desvio não-permissível de pelo menos uma propriedade, característica ou parâmetro do sistema, a partir de uma condição aceitável, usual ou padrão [197].

a vida da ferramenta é aumentada, alguma exatidão no processo de usinagem é diminuída, devido a um crescimento da deflexão na peça ou por causa da presença de vibrações [16].

A figura 2.7 ilustra o aspecto da ferramenta de corte com os principais tipos de falha durante as operações de torneamento. Os efeitos superficiais representam os desgastes (no flanco e na face) e os efeitos volumétricos as avarias (trincas e fraturas).




Figura 2.7 – Tipos de falha na ferramenta de corte em torneamento [19]

### (f) Acabamento da Superfície Usinada

Acabamento é um termo coloquial largamente usado para designar a qualidade geral de uma superfície usinada. A Figura 2.8 esquematiza a classificação de acabamento [20].

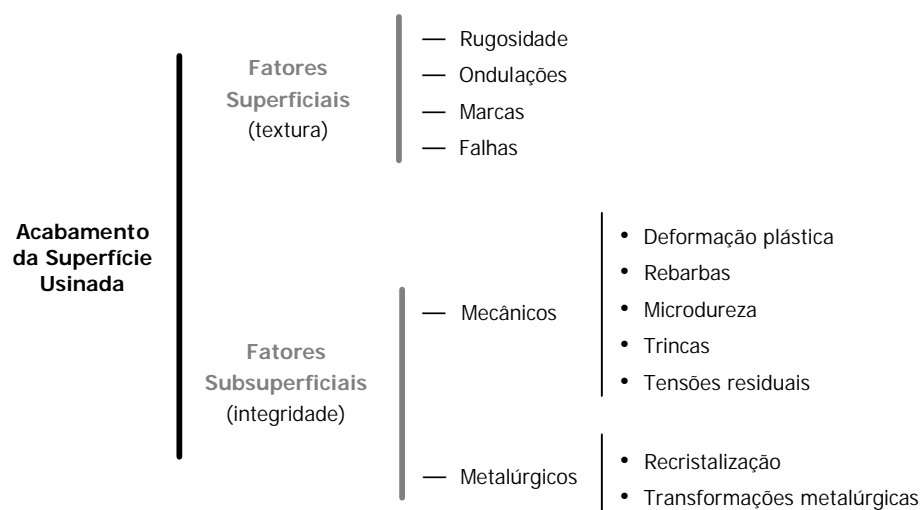


Figura 2.8 – Classificação de acabamento [20]

A **textura** está relacionada com as irregularidades presentes na superfície de materiais sólidos e com as características dos instrumentos de medição; é definida em termos de rugosidade, ondulação, marcas e falhas. A **integridade** é a característica através da qual podem ser relacionadas ou identificadas as diversas exigências ou alterações metalúrgicas que poderão desenvolver-se devido ao processo de usinagem, tais como: transformações de fases, distribuição e tamanho de grão, recristalização, inclusões no material etc. [38]. O objetivo da usinagem é obter uma superfície técnica que apresente fatores superficiais e subsuperficiais apropriados, a fim de garantir segurança, confiabilidade e longa vida ao componente fabricado – principalmente quando vidas humanas estão em jogo.

Como durante a usinagem as energias (do processo) misturam-se com as propriedades do material da peça, podem conseqüentemente surgir efeitos superficiais tais como rugosidade, trincas e tensões residuais. A combinação destes efeitos pode gerar desgaste ou fadiga na peça [34]. Além disso, todo processo possui alguma variabilidade inerente que se modifica com quase todas as variáveis de entrada. Assim, é necessário selecionar apropriadamente os níveis das variáveis independentes de modo a se obter um componente com as tolerâncias (especificadas pelo projeto) e propriedades (técnicas superficiais) satisfatórias.

O acabamento não está especificamente ligado à textura ou padrão característico da superfície técnica, nem a valores específicos de rugosidade. Contudo, um “bom” acabamento implica baixos valores de rugosidade, e vice-versa [39]. Assim, a habilidade de uma operação de usinagem em produzir um acabamento específico depende de muitos fatores: ferramenta, peça, processo, parâmetros de corte e meio lubri-refrigerante [34].

Em geral, a qualidade de uma superfície usinada é classificada apenas em termos do parâmetro rugosidade, cujos valores medidos são normalmente expressos pelo desvio médio aritmético de rugosidade ( $R_a$  – *roughness average*) ou pela profundidade máxima de rugosidade ( $R_{máx}$  ou  $R_t$ ) [38]. O parâmetro “ $R_a$ ” é o parâmetro de medição mais utilizado em todo o mundo, principalmente em superfícies nas quais: (a) o controle contínuo da rugosidade nas linhas de produção faz-se necessário; (b) o acabamento apresenta sulcos de usinagem bem orientados, e.g. torneamento; (c) exige-se pouca responsabilidade, como no caso de acabamentos com fins apenas estéticos.

Como as variáveis dependentes de saída são determinadas pelo processo, baseando-se na prévia seleção das variáveis independentes de entrada, o Capítulo 3 irá abordar o assunto **Vida da Ferramenta**, definindo os critérios para seu estabelecimento.

## 3 - VIDA DA FERRAMENTA



*“Uma estratégia conservadora de substituição da ferramenta reduz a probabilidade de falha no processo. Conseqüentemente, a interrupção freqüente diminui a produtividade e aumenta o custo. Assim, busca-se sempre determinar o momento mais apropriado para isso”.*

L. ALDEN KENDALL

Em função das condições de corte durante o processo de usinagem, a ferramenta fica sujeita a uma combinação de vários fatores de origem térmica, mecânica, química e abrasiva (elevada pressão de contato entre peça-ferramenta-cavaco). Como nem o material da peça nem o da ferramenta de corte são homogêneos, uma série de avarias e desgastes de naturezas distintas pode ser observada na ferramenta durante sua utilização. Em decorrência de tais solicitações, a deterioração da mesma torna-se relativamente rápida.

Diversos mecanismos de desgaste agem simultaneamente, de forma que tanto sua causa quanto seu efeito dificilmente podem ser distinguidos entre si. Dependendo da natureza do material usinado e das condições de usinagem, predominará um ou outro mecanismo sobre os demais. O conhecimento do mecanismo de desgaste é de grande interesse, pois permite uma seleção criteriosa da ferramenta mais indicada e das condições mais apropriadas de usinagem.

### 3.1 Mecanismos e Processos de Falhas

A literatura apresenta variações na classificação dos mecanismos e processos de falhas em ferramentas de corte. Porém, grande parte dos trabalhos existentes considera pelo menos 6 (seis) diferentes mecanismos (processos): (a) solicitações mecânicas e térmicas excessivas; (b) abrasão mecânica; (c) adesão; (d) difusão; (e) entalhe; e (f) oxidação.

Os diversos mecanismos (processos) de falhas em ferramentas de corte agem simultaneamente, de forma que tanto sua causa como seu efeito dificilmente podem ser distin-

guidos entre si [19]. Todos eles são observados na prática, mas certamente um prevalecerá sobre os demais, dependendo principalmente do material da peça e da ferramenta, da operação de usinagem, das condições de corte, da geometria da ferramenta de corte e o do emprego do meio lubri-refrigerante [20].

### (a) Solicitações térmicas e mecânicas excessivas

Os processos de avarias tais como trincas (transversais e longitudinais), lascamentos<sup>10</sup>, bem como deformação plástica advém de solicitações térmicas e mecânicas excessivas. As ferramentas mais susceptíveis a estes tipos de solicitações localizadas são as de metal-duro e cerâmica, resistentes ao desgaste, principalmente nas operações de usinagem com seções de corte muito pequenas [19].

Muitas vezes, excessivas forças de usinagem levam a micro e macrolascamentos<sup>11</sup> do gume ou da quina, principalmente quando o ângulo de cunha ( $\beta$ ) ou de quina ( $\epsilon_r$ ) da ferramenta são muito pequenos, ou o material da ferramenta é demasiadamente frágil. Neste caso, a direção da trinca é definida pela linha de ação dessa força [19]. Cortes interrompidos também podem provocar lascamentos.

Em cortes interrompidos (e.g. fresamento), o gume é submetido a um grande esforço alternante. Esta solicitação alternante compressiva pode levar à fadiga da cunha de corte. As rápidas variações das forças de usinagem podem levar a trincas longitudinais (paralelas ao gume) por esforços mecânicos. Já as trincas transversais (perpendiculares ao gume) são avarias decorrentes de solicitações térmicas alternadas. Essas solicitações ocorrem principalmente no corte interrompido. Durante a entrada da ferramenta, o gume aquece-se rapidamente a elevadas temperaturas. Após a sua saída da peça, ocorre o resfriamento. A dilatação térmica gera tensões que levam à trinca do material. O crescimento de trincas leva à quebra da ferramenta [22].

As deformações plásticas no gume ocorrem quando o material da ferramenta amolece devido à pressão aplicada na ponta da ferramenta somada às altas temperaturas. O escoamento do material se dá pela ação das forças de usinagem. A cunha da ferramenta tende a sofrer maior deformação quanto mais próxima estiver a temperatura da cunha durante a usinagem da temperatura de fusão do material da ferramenta. Deformações plásticas po-

---

<sup>10</sup> **Lascamento** é o termo usado para descrever a fragmentação do gume da ferramenta de corte em pequenos pedaços. Diferente do desgaste, que é um processo gradativo, esta falha resulta na perda repentina de material e da conseqüente afiação da ferramenta, afetando o acabamento da superfície usinada [21].

<sup>11</sup> Os **microlascamentos** apresentam marcas de falha (área) cuja ordem de grandeza pode variar de 0,03 a 0,10 mm<sup>2</sup>, nos **lascamentos** de 0,05 a 0,30 mm<sup>2</sup>, e nas **quebras** valores superiores a 0,15 mm<sup>2</sup> [16].

dem ocorrer em ferramentas de metal-duro, entretanto sob maiores velocidades de corte e esforços que nas de aço-rápido [19]. O crescimento da deformação plástica pode gerar a quebra do gume. Pode ser evitado empregando ferramentas com maior dureza à quente, mudando as condições de corte, ou alterando a geometria da ferramenta visando a diminuição dos esforços e da temperatura na região de corte [22].

### (b) Abrasão mecânica

A abrasão mecânica é o “arrancamento” de finas partículas de material, em decorrência do escorregamento sob alta pressão e temperatura (atrito) entre a peça e a ferramenta. Este mecanismo de desgaste aumenta com o número de inclusões e partículas duras no material usinado [21]. A abrasão é uma das principais causas do desgaste de flanco, já que o atrito da ferramenta é mais intenso com a peça que com o cavaco (por questão de maior rigidez da peça). Assim, quanto maior a dureza a quente da ferramenta, maior a sua resistência ao desgaste abrasivo. Às vezes, partículas duras arrancadas de outra região da ferramenta por aderência e arrastamento [item (d)], ou mesmo por abrasão, e arrastadas pelo movimento da peça, causam o desgaste abrasivo em uma área adjacente da ferramenta de corte [22].

### (c) Difusão

A difusão consiste na transferência de átomos pertencentes à rede cristalina de um material para outro, constituídos de elementos químicos que apresentam afinidade entre si. Quanto maiores forem a afinidade química, a temperatura de contato e o tempo de contato, maior será a difusão entre a ferramenta e o cavaco [17]. Este mecanismo poderá atuar tanto na face quanto no flanco da ferramenta, e a taxa de desgaste irá aumentar com o acréscimo da velocidade de corte e do avanço [20]. Como a difusão ocorre com maior intensidade na região de maior temperatura (fig. 3.1), o desgaste de cratera apresenta uma forte semelhança com as curvas isotermas da região de corte [19].

### (d) Adesão

Geralmente, a adesão ocorre em baixas velocidades e temperaturas de corte, onde o fluxo de material sobre a superfície de saída da ferramenta se torna irregular [20]. No contato das superfícies, fragmentos microscópicos dos materiais da peça e da ferramenta se aderem, e em seguida são arrancados da superfície da ferramenta e arrastados junto ao fluxo de material adjacente. O fenômeno da adesão está presente na formação do gume postiço,



mas pode-se ter desgaste por ruptura sem formação deste. Também é importante na formação do desgaste de entalhe. Normalmente, em cortes interrompidos, profundidades de corte irregulares, ou na falta de rigidez do sistema, há o fluxo irregular de material, e, portanto, o desgaste de adesão por ruptura. A utilização de ferramentas recobertas com materiais de baixo coeficiente de atrito ameniza seu desenvolvimento [22].

### (e) Entalhe

O desgaste de entalhe é considerado um processo ao invés de um mecanismo de desgaste por TRENT E WRIGHT [18]. Ele é caracterizado pela formação de entalhes profundos em forma de 'V' nos gumes principal e secundário, ocorrendo principalmente na usinagem de materiais resistentes a elevadas temperaturas, tais como: ligas de níquel, titânio, cobalto etc. Ainda não existe um consenso entre os pesquisadores que explique exatamente o mecanismo que provoca o entalhe. Por esta razão, é comum tratar esta forma de desgaste como um mecanismo [20]. Geralmente, nas regiões onde ocorrem entalhe, as condições de escorregamento prevalecem e o mecanismo de desgaste, provavelmente, envolve abrasão [item (b)] e transferência de material [difusão, item (c), e adesão, item (d)], e eles são bastante influenciados pelas interações com a atmosfera [40]. TRENT E WRIGHT [18] sugeriram que óxidos se formariam continuamente na interface cavaco-ferramenta, aderindo-se então à ferramenta, sendo que a quebra das junções de aderência entre os óxidos e a ferramenta poderia, ocasionalmente, remover material da superfície desta última. Entretanto, SHAW *et al.*<sup>12</sup> afirmam que o entalhe na forma de 'V' é formado pelas rebarbas produzidas nas arestas laterais do cavaco, envolvendo o mecanismo de adesão [item (d)].

### (f) Oxidação

Altas temperaturas e a presença de ar e água (presentes nos meios lubrificantes) geram oxidação na maioria dos metais. A oxidação depende do material da ferramenta. O metal-duro inicia sua oxidação entre 700 e 800°C, principalmente no gume secundário, onde ocorre a formação de um óxido de tungstênio, cobalto e ferro, que em decorrência do seu maior volume em relação ao carboneto de tungstênio, forma "bolhas" na superfície da ferramenta, levando ao lascamento e quebra do gume. A adição de carbonetos de titânio, tântalo e vanádio dificultam a oxidação do metal-duro [19]. Assim, em função do


---

<sup>12</sup> SHAW, M. C *et al.* (1966). A plasticity problem involving plane strain and plane stress simultaneously: groove formation in the machining of high-temperature alloys. *ASME Journal of Engineering for Industry*, p.142-146 *apud* MACHADO E SILVA [20].

tipo de material da ferramenta e das condições de corte, haverá mais ou menos desgaste por oxidação. Segundo DINIZ *et al.* [22], o desgaste gerado pela oxidação se forma especialmente nas extremidades do contato cavaco-ferramenta devido ao acesso do ar nesta região, sendo esta uma possível explicação para o surgimento do desgaste de entalhe.

## 3.2 Desgastes e Avarias da Ferramenta

Durante a usinagem dos metais, a ação de corte altera a forma e, portanto, a geometria original da ferramenta de corte, pois se verificam desgastes progressivos no flanco (superfície de incidência) e na face (superfície de saída) da ferramenta. A figura 3.1 esquematiza os tipos de desgaste presentes na ferramenta de corte e a figura 3.2 mostra uma padronização típica de desgastes de ferramentas de metal-duro. O desgaste de cratera na face, a marca de desgaste no flanco e o entalhe são os desgastes típicos [16; 40].



**Figura 3.1** – Esquema dos tipos de desgaste da ferramenta de corte: (a) desgaste de cratera; (b) desgaste de flanco; (c) e (d) entalhe [20]

A norma ISO 3685 [40] determina os parâmetros de medida dos **desgastes** desenvolvidos no **flanco** e na face da ferramenta (fig. 3.2). No flanco mede-se a largura da marca de desgaste (VB), sendo:  $VB_B$  o desgaste médio de flanco;  $VB_{máx}$  o desgaste máximo de flanco;  $VB_N$  o desgaste de entalhe no gume principal;  $VB_C$  o desgaste de entalhe no gume secundário. Na face mede-se a profundidade da **cratera** (KT) e a distância do centro da cratera ao gume (KM).




Figura 3.2 – Padrão de desgaste para uma ferramenta de metal-duro [16; 40]

No caso das avarias, elas podem ser subdivididas em: **deformações plásticas**, **trincas** e **fraturas** (**lascamentos** e **quebra**). Segundo MACHADO E SILVA [20], as trincas térmicas (devido ao aumento do gradiente de temperatura a cada entrada da ferramenta na peça) são a maior causa das falhas da ferramenta em altas velocidades de corte. Já as trincas mecânicas (por causa dos choques mecânicos na entrada e/ou na saída da ferramenta na peça – principalmente em operações de fresamento) são as principais responsáveis pelas falhas (geralmente lascamentos) em baixas velocidades de corte. STEMMER [21] afirma que o lascamento é uma falha acidental e prematura que pode ocorrer quando a ferramenta é pouco resistente (ângulo de quina “ $\epsilon_r$ ” muito pequeno; pastilha muito dura e pouco tenaz) ou quando acontecem sobresolicitações de origem mecânica (impactos ferramenta-peça; peça com inclusões duras; vibrações) ou térmica (resfriamento brusco). Já FERRARESÍ [31] classifica a quebra como a ruptura da quina ou do gume pela ação de grandes forças de usinagem. Para finalizar, DIEI E DORNFIELD [41] explicam que a diferença entre microlascamento, lascamento e quebra está na dimensão da fratura, a qual é definida pelo volume de material perdido pela ferramenta.

Quando a abrasão é a principal causa do desgaste de flanco, os padrões de desgaste são relativamente uniformes e fáceis de mensurar. Por exemplo, o tempo necessário para que a largura média da marca de desgaste de flanco ( $VB_a$ ) atinja 0,3 mm é um padrão usual de fim de vida, embora esta abordagem esteja mais ligada às falhas na ferramenta que propriamente aos problemas de acabamento e/ou tolerância da peça. Contudo, quando lasca-

mentos gerados por adesão ou sobrecarga mecânicas e/ou térmicas são a causa do desgaste de flanco, o padrão é geralmente irregular, resultante principalmente da usinagem de materiais de difícil corte. Neste caso, “ $VB_B$ ” não mais determina a vida. Recomenda-se que seja considerada a largura máxima da marca de desgaste de flanco ( $VB_{máx}$ ). A zona onde “ $VB_{máx}$ ” ocorre pode fornecer informações úteis sobre o mecanismo de desgaste e como ele pode ser reduzido [16]. Em geral, para caracterizar fim de vida,  $VB_{máx} \geq 0,6$  mm [40].

O desgaste de cratera se manifesta sob a forma de cavidade na face da ferramenta. O desenvolvimento deste tipo de desgaste está diretamente ligado à temperatura e à pressão de corte. Ao contrário do desgaste de flanco, o desgaste de cratera não influencia na rugosidade ou na tolerância, mas sim na geometria do ângulo de saída ( $\gamma$ ) e no comprimento de contato cavaco-ferramenta. Ele pode, em condições térmicas inadequadas e para alguns tipos de materiais (peça), resultar em fraturas na ferramenta devido à fragilidade do gume. A profundidade de cratera “KT” entre 0,05 e 0,1 mm é geralmente usada como critério de fim de vida [16]. Talvez o principal inconveniente de “KT” esteja na dificuldade de sua quantificação. FERRARESI [31] mostra que a medição de “KT” é feita geralmente por perfilômetros especiais, onde uma agulha apalpadora com uma ponta de safira com raio de 10  $\mu$ m percorre a superfície a ser examinada; o movimento da agulha é então ampliado mecânica e opticamente para que o perfil da superfície possa ser registrado.

Em geral, os desgastes se apresentam como falhas contínuas, isto é, possuem comportamento determinístico (podem ser modeladas matematicamente) ao longo de sua progressão até a deterioração completa da ferramenta. Isto permite um controle maior da vida. Por outro lado, as avarias (ou fraturas) são falhas transitórias que ocorrem aleatoriamente (não podem ser descritas por uma função matemática explícita), levam a ferramenta ao colapso<sup>13</sup> (quebra total) e freqüentemente são detectadas somente após o ocorrido [42]. No lascamento do gume, por exemplo, a superfície usinada pode ficar extremamente danificada [43] sem falar na quebra, que pode acarretar danos irreversíveis à peça [44; 45].

### 3.3 Vida da Ferramenta

A vida de uma ferramenta pode ser definida como sendo o tempo em que a mesma trabalha efetivamente, sem perder a capacidade de corte, dentro de um critério previamente estabelecido. Em outras palavras, a ferramenta trabalhando em condições normais de corte

---

<sup>13</sup> Colapso é uma interrupção permanente da habilidade da ferramenta em desempenhar a função de corte sob condições operacionais específicas [197].

é usada até que o seu desgaste, previamente fixado, seja tal que exija a sua substituição [31]. Assim, a ferramenta deve ser substituída quando se observar:

- ☑ Valores elevados de desgastes podendo levar à quebra da ferramenta.
- ☑ Temperaturas excessivas atingidas pela ferramenta.
- ☑ As tolerâncias dimensionais fogem do controle.
- ☑ Acabamento superficial deixa de ser satisfatório.
- ☑ As componentes da força de usinagem aumentam excessivamente.

Valores médios e máximos da marca de desgaste de flanco indicados pela norma ISO 3685 [40], respectivamente  $VB_B = 0,3$  mm e  $VB_{máx} = 0,6$  mm, são para ensaios de fim de vida. Industrialmente, tais parâmetros podem assumir valores diferentes, pois dependem das condições de trabalho de cada empresa. A prática utilizada é trabalhar com a ferramenta até que as peças produzidas saiam das especificações de tolerância dimensional e acabamento superficial ditadas pelo projeto. Têm-se assim dois fatores decisivos na determinação das condições de usinagem para a vida da ferramenta. DINIZ *et al.* [22] mostram que em torneamento de acabamento, o valor de “VB” não deve exceder 0,2 mm para uma qualidade IT7 e 0,3 mm para uma qualidade IT8. FERRARESI [31] sugere o controle através: do tempo de corte, do volume de material removido ou o número de peças usinadas. Entretanto, a continuação do uso do gume depois de superados os critérios preestabelecidos traz sérios riscos, pois valores excessivos de desgastes causam aumento da força de usinagem e geração de calor, podendo provocar fratura na ferramenta e danos irreversíveis à peça.

Os principais problemas relacionados à fixação de um determinado valor-limite de desgaste para o fim de vida da ferramenta estão associados com o tipo de operação [22]:

- ☑ Em operações de **desbaste** (onde se toleram altos valores de desgaste), por temer que a ferramenta quebre, costuma-se trocar a ferramenta bem antes, com valores de desgaste bastante inferiores àqueles que poderiam provocar tal avaria.
- ☑ Em operações de **acabamento** é relativamente simples detectar quando as dimensões da peça saem das faixas de tolerâncias projetadas (desgastes na ferramenta). Em geral, utiliza-se um calibrador passa-não-passa ou algum outro instrumento e procede-se a medição por amostragem. Neste caso, não é necessário trocar a ferramenta imediatamente, pois ainda é possível corrigir a posição da ferramenta e continuar a usinagem com o mesmo gume (compensação de desgastes em máquinas com CNC).

Da mesma forma que diversos fatores influenciam os mecanismos de desgaste na ferramenta, vale salientar que diferentes variáveis influenciam direta ou indiretamente no tempo de vida de uma ferramenta [18; 31; 32; 37]:

- ☑ **Peça:** natureza do material; composição química; processo de fabricação; tratamento térmico; propriedades físicas, químicas, mecânicas; microestrutura; dimensões e forma.
- ☑ **Ferramenta:** tipo de material; geometria; composição; propriedades químicas, físicas e mecânicas; largura da marca de desgaste de flanco (critério de fim de vida).
- ☑ **Máquina:** tipo de máquina; rigidez; velocidade de corte (parâmetro mais significativo), avanço e profundidade de corte; área de seção de corte; forma da seção de corte; meio lubri-refrigerante (tipo, propriedades lubrificantes, forma de aplicação etc.).

Segundo STEMMER [21], a vida da ferramenta é evidentemente influenciada pelas dimensões do corte. Como regra geral, a combinação de uma profundidade de corte ( $a_p$ ) máxima possível e de um grande avanço ( $f$ ) com uma baixa velocidade de corte ( $v_c$ ) determina uma alta taxa de remoção de material durante uma dada vida da ferramenta. A aplicação desta regra é bastante vantajosa na usinagem de desbaste de peças estáveis em máquinas rígidas, que permitem operações de corte pesadas. Os limites de aplicação desta regra são dados pela progressiva piora do aspecto da superfície usinada e pelo aumento das forças atuantes na ferramenta, na peça e na máquina. No limite há, pois, problemas de qualidade de acabamento, dificuldade de sujeição da peça que escorrega na placa, empenamento da peça, quebra da ferramenta, deformações elásticas na máquina-ferramenta etc.

Assim, o tempo de vida da ferramenta pode ser estimado pela equação (3.1) [21]:

$$\left(\frac{T}{60}\right)^n = \frac{C_v \cdot \left(0,2 \cdot \frac{a_p}{f}\right)^g}{v_c \cdot (a_p \cdot f)^s} \quad (3.1)$$

onde:

$C_v$  = constante cujo valor depende da máquina, da ferramenta e da peça. Seu valor corresponde a uma velocidade de corte que resulta numa vida de um minuto.

$n$  = expoente que depende da máquina, da ferramenta e da peça.

$g$  = expoente do índice de esbeltez do cavaco ( $a_p/f$ ).

$s$  = expoente da área de seção de corte ( $a_p \cdot f$ ).

Tendo o conhecimento prévio sobre os mecanismos de desgastes e os tipos de falhas a eles associados (dentro do contexto de vida da ferramenta de corte), no Capítulo 4 far-se-á a **Formulação do Problema**, expondo de uma forma geral quais os principais objetivos da aplicação de sistemas de monitoramento em processos de usinagem.

## 4 - FORMULAÇÃO DO PROBLEMA



*“É praticamente impossível prever o desempenho no corte dos metais. Entretanto, isto não quer dizer que estudos detalhados dos processos de usinagem não têm valor. Cada ponto fundamental que é detalhadamente estudado e propriamente interpretado contribui para o entendimento do processo, e o **entendimento** é o passo mais próximo da capacidade de prever”.*

MILTON C. SHAW

Existem diferentes critérios para o estabelecimento do fim de vida de uma ferramenta, cada um com suas considerações. Basicamente, estes critérios podem ser divididos em falhas na ferramenta, tolerâncias da peça, degradação do acabamento da superfície usinada e fatores econômicos.


Em laboratórios, as falhas na ferramenta são frequentemente usadas como critério de fim de vida por serem facilmente quantificadas [16]. Sob condições normais de usinagem, o desgaste de flanco é usualmente escolhido como base para a avaliação do estado da ferramenta de corte nos diversos sistemas de monitoramento *on-line* desenvolvidos, pois influencia diretamente nos erros dimensionais e na rugosidade da peça. Assim, este desgaste merece grande atenção daqueles que procuram o desenvolvimento de sensores para o monitoramento indireto.

Nas ferramentas de metal-duro, o desgaste no flanco é geralmente maior que na face. Os desgastes aumentam progressivamente até a quebra do gume, que deve ser evitada devido às suas conseqüências danosas. Na usinagem de muitos materiais, esta quebra se dá para valores de “VB” entre 0,8 e 1,5 mm. Em operações de acabamento, a ferramenta deve ser retirada muito antes do desgaste atingir valores que ponham em risco o gume, a fim de não comprometer a precisão da peça e seu acabamento [22].

Segundo WELLS [46], a troca da ferramenta por ter atingido seu fim de vida apresenta pouca contribuição no tempo de parada de um sistema de manufatura integrado (CIM) e flexível (FMS). Além disso, as trocas efetuadas durante o processo (principalmente devido ao desgaste excessivo) ocorrem em intervalos razoavelmente regulares e previsíveis. Por outro lado, as avarias na ferramenta, quando ocorrem, têm importantes conseqüências econômi-

cas. No lascamento do gume, por exemplo, a superfície usinada pode ficar extremamente danificada [43], sem falar na quebra, que pode acarretar danos irreversíveis à peça [44].

O estudo de VARMA E KLINE [3] mostra que a pastilha, quando atinge seu fim de vida (por desgaste ou quebra), envolve custos da ordem de alguns poucos dólares. Já eventos como a quebra do suporte ou a danificação da máquina-ferramenta podem custar centenas ou milhares de dólares de manutenção. Um evento desastroso, de proporções elevadas, raramente acontece (talvez duas ou três vezes ao ano); mas quando acontece, além do custo agregado ser altíssimo (parada da linha de produção, reposição de peças danificadas, mão-de-obra especializada na manutenção), corre-se o risco de se perder a exatidão da máquina, muitas vezes de maneira irreversível. A figura 4.1 mostra o custo estimado envolvido na manutenção corretiva, relativo aos eventos que podem ocorrer durante a usinagem.



**Figura 4.1** – Custo estimado dos eventos em usinagem [3]

Assim, para que os eventos representados na figura 4.1 sejam evitados e os custos minimizados, o sistema de monitoramento deve ser capaz de responder imediatamente a uma provável colisão, estimar (ou classificar) a largura da marca de desgaste de flanco e detectar rapidamente qualquer tipo de avaria.

## 4.1 Resposta Imediata à Colisão

Para efeito de análise, dois diferentes tipos de embate precisam ser devidamente distinguidos: colisão e sobrecarga.



Uma **colisão** pode ser definida como sendo um impacto repentino na movimentação do carro porta-ferramenta(s) contra outra parte da máquina (placa ou contra-ponto) ou contra a peça, durante o corte ou não. Este tipo de colisão geralmente acarreta conseqüências financeiras dispendiosas, já que parte da máquina, a ferramenta de corte (pastilha e suporte) e/ou a peça podem ser totalmente destruídas. Além disso, a conseqüente interrupção do processo produtivo gera grandes prejuízos financeiros. Ela geralmente resulta de uma falha causada pelo operador (erro de programação ou distração) ou pela própria máquina (falha nos sensores de posicionamento ou de fim de curso). Por conseguinte, e devido ao fato dos eixos geralmente se movimentarem em altas velocidades, é difícil interromper a inércia do carro porta-ferramenta(s) a tempo de prevenir graves danos devido à sua massa elevada. Entretanto, é necessário impedir a colisão tão rápido quanto for possível e parar a máquina-ferramenta. Devido ao impacto repentino, a detecção da colisão severa é possível usando sensores de vibração de baixa freqüência, transdutores de deformação ou sensores de força (maiores detalhes no Capítulo 6). A velocidade de resposta, desde a detecção de contato até a parada da máquina, depende da capacidade de processamento do comando numérico computadorizado (CNC) com arquitetura de controle aberta [47].

Uma **sobrecarga** é caracterizada por um aumento relativamente lento das forças no sistema. Este evento pode levar a ferramenta à destruição, danos na peça e até nos componentes da máquina-ferramenta. A sobrecarga ocorre principalmente por causa do uso de condições inadequadas de corte e peças com sobremetal excessivo. Pelo fato deste tipo de embate se desenvolver vagarosamente, é usualmente possível parar a máquina antes que a pastilha se quebre [48].


Devido ao fato que diferentes tipos de sobrecarga não resultam em impactos ocasionais de alta intensidade, sua detecção é considerada bem mais complexa que a da colisão. Logo, seria necessário considerar a análise de sinais de diferentes sensores, e.g., força, vibração e emissão acústica (maiores detalhes no Capítulo 6). Como a velocidade de resposta não precisa ser tão alta quanto na colisão, um maior tempo pode ser empregado na avaliação desta estratégia de medição [48].

## 4.2 Estimativa ou Classificação de Falhas Contínuas

Na usinagem de corte em metais, o desgaste da ferramenta não pode ser ignorado. Ferramentas desgastadas geram qualidades insatisfatórias na superfície usinada, assim como erros dimensionais de forma e tamanho da peça. Além disso, o risco de quebra na ferramenta aumenta. Assim, a detecção automática de ferramentas desgastadas é essencial

para garantir um processo livre de erros. Devido ao fato da qualidade da peça ser o ponto mais importante, não basta coletar informações somente do estado da ferramenta, mas também o acabamento gerado na peça.

A figura 4.2 ilustra as fotos comparativas de dois gumes de um inserto de metal-duro registradas durante os ensaios de torneamento do presente trabalho: gume novo (1 minuto) e gume desgastado (14 minutos).




**Figura 4.2** – Fotos do gume de um inserto de metal-duro em torneamento a seco do aço ABNT 1040 com  $f = 0,3$  mm,  $v_c = 350$  m/min e  $a_p = 1,5$  mm em tempos de vida diferentes

Quando se utilizam ferramentas de metal-duro revestidas, o desgaste no flanco cresce de maneira bastante lenta e contínua, devido à alta resistência ao desgaste das camadas de revestimento, até atingir valores de “VB” da ordem de 0,3 a 0,4 mm. Neste momento, as camadas de revestimento já estão quase que totalmente consumidas pelo desgaste e, então, o corte passa a ser realizado pelo substrato da ferramenta – bem menos resistente ao desgaste –, o que faz com que o desgaste cresça de forma abrupta e descontínua, chegando a valores da ordem de 0,8 a 1,0 mm num intervalo de tempo bem reduzido. Assim, para evitar a fratura do gume por fragilização (falta de revestimento), a ferramenta deve ser substituída quando esse momento chega [22].

### 4.3 Identificação de Falhas Transitórias

A fratura da ferramenta usualmente acarreta uma parada na produção. Além disso, pode trazer conseqüências caras e desastrosas se a falha não for identificada e, por conseguinte, refugos forem produzidos. Portanto, a detecção de fraturas (microlascamentos, lascamentos e quebra) tem uma alta prioridade na usinagem de acabamento.

A figura 4.3 mostra a foto de um gume (inserto de metal-duro revestido) fraturado após 20 minutos de ensaio de torneamento realizado durante este trabalho.



Após 20 minutos

**Figura 4.3** – Foto do gume de um inserto de metal-duro em torneamento a seco do aço ABNT 1040 com  $f = 0,3$  mm,  $v_c = 350$  m/min e  $a_p = 1,5$  mm fraturado

Por causa da diferente natureza desses eventos, duas diferentes estratégias devem ser aplicadas. No caso da quebra e do lascamento, considera-se que a detecção é possível com base na mudança súbita do nível de amplitude do sinal sensório [45]. Já o microlascamento requer uma avaliação mais detalhada das características do sinal. Assim, a identificação de microlascamentos não é tão simples e rápida quanto a identificação de lascamentos e quebra.

Na usinagem de acabamento, todas as falhas transitórias devem ser prontamente identificadas a fim de não causarem danos subsequentes, apesar da detecção de quebra na ferramenta ter maior prioridade. Nas operações de desbaste, a detecção de microlascamentos no gume possui importância secundária.

A partir dos problemas previamente apresentados e suas conseqüências no processo, mostrou-se de forma sintetizada no Capítulo 4 a importância da supervisão na minimização dos efeitos causados pelas falhas da ferramenta. Assim, o Capítulo 5 apresentará o procedimento de **Monitoramento do Estado da Ferramenta de Corte**, desde a seleção e aquisição de informações até a tomada de decisão perante o problema detectado.

## 5 - MONITORAMENTO DO ESTADO DA FERRAMENTA



*"A usinagem de metais é um fenômeno complexo que tem sido estudado há décadas. Já o monitoramento do estado da ferramenta de corte é uma necessidade prática que está longe de ser realizada efetivamente".*

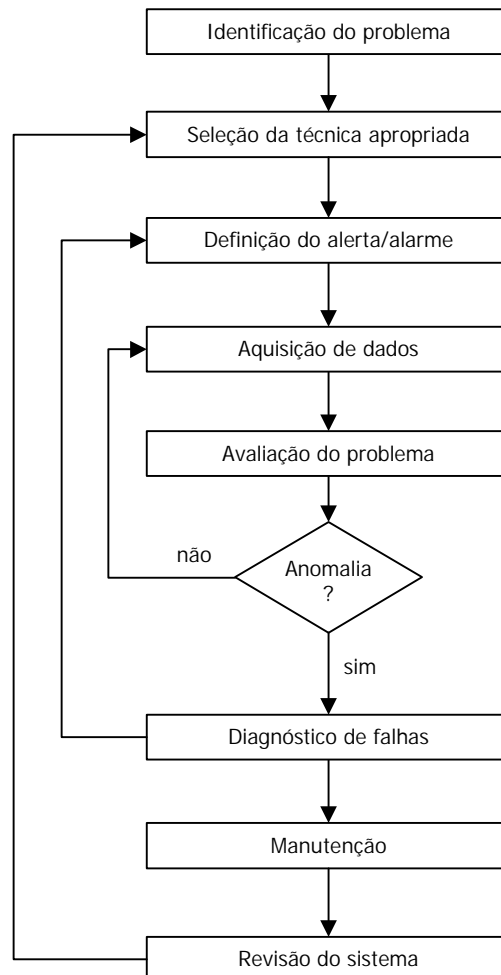
BERNHARD SICK

Em geral, o processo de torneamento depende bastante da intervenção humana na detecção de anomalias, na inspeção da qualidade da peça usinada e no controle do processo. Em suma, a tomada de decisões cabíveis ainda depende fortemente da habilidade do operador. Quando a máquina-ferramenta é utilizada numa condição isolada, o operador se faz presente, com o principal objetivo de supervisionar a ferramenta de corte e outras funções durante o processo. Tipicamente, o operador irá assegurar que o sistema máquina-ferramenta-peça está atuando de maneira satisfatória. Por outro lado, quando a tecnologia moderna é aplicada em sistemas de fabricação, deseja-se que as operações dependam o mínimo possível da assistência humana na tarefa de supervisão e controle do processo. Esta ausência, mesmo que parcial de um operador, acarretará um número considerável de variáveis que deverão ser consideradas para que o sistema atue satisfatoriamente. Assim, um sistema de monitoramento deve ser provido de recursos necessários para suprir tal ausência, possibilitando a emissão de informações e instruções à máquina e/ou ao operador sobre o processo [47]. A figura 5.1 esquematiza as etapas da elaboração deste sistema [49].


Um sistema de monitoramento do estado da ferramenta de corte (TCM) é basicamente um conjunto de elementos que primeiramente selecionam e adquirem informações de uma fonte específica (sensores), depois tratam e refinam tais informações (extração de características) e em seguida, tomam a decisão baseada nas informações refinadas (reconhecimento de padrões) [50]. A figura 5.2 ilustra os elementos básicos de um sistema TCM.

Normalmente, diferentes parâmetros do processo de torneamento são mensurados de forma indireta e contínua (*on-line*) em sistemas TCM inteligentes. As informações provenientes de múltiplos e diferentes sensores (e em alguns casos também informações adicio-

nais provenientes do operador ou de uma base de dados) são combinadas com o intuito de tomar a decisão mais apropriada sobre o estado da ferramenta de corte.



**Figura 5.1** – Processo de elaboração de um sistema de monitoramento [49]



**Figura 5.2** – Sistema de monitoramento do estado da ferramenta [50]

Sick [12] mostra que um sistema TCM inteligente consiste na maioria das vezes de uma seqüência de subsistemas para a condução dos dados, desde a detecção dos sinais até o diagnóstico<sup>14</sup> do estado da ferramenta: aquisição (sensoriamento); pré-processamento

<sup>14</sup> O **diagnóstico de falhas** consiste na determinação do tipo, do tamanho, da localização e do período de detecção da falha. Envolve as etapas de (a) detecção, (b) isolamento e (c) identificação da falha [197].

(condicionamento de sinais); representação (tratamento de sinais); avaliação e resposta (reação ou tomada de decisão). A figura 5.3 mostra tal representação.

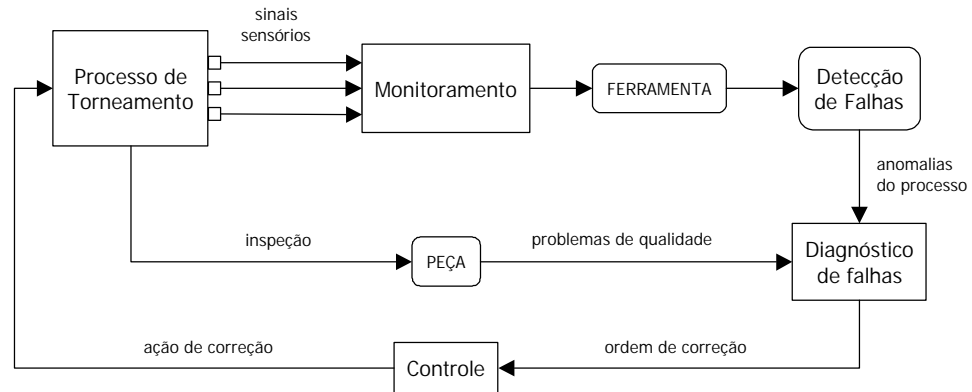


Figura 5.3 – Sistema inteligente de monitoramento do estado da ferramenta [51]

## 5.1 Sensoriamento

O monitoramento do processo pode ser independente do tempo de execução (durante os intervalos do processo) ou dependente do tempo, ocorrendo em tempo real (simultaneamente ao processo). Esta classificação pode ser relacionada com os métodos de medição das falhas da ferramenta, respectivamente, **medição direta** (*off-line*) e **medição indireta** (*on-line*) [9]. O primeiro método interrompe o processo e então quantifica diretamente o valor do desgaste na ferramenta através de equipamento apropriado. O segundo método acompanha e avalia uma grandeza física – mensurável em tempo real – que pode ser correlacionada com o desgaste da ferramenta durante o processo<sup>15</sup>. Ambos os sistemas de medição requerem um certo grau de habilidade para os devidos ajustes e interpretações das informações obtidas.

Através de modelos analíticos ou empíricos apropriados<sup>16</sup>, é possível tirar conclusões sobre os benefícios destes métodos de medição na informação sobre o estado da ferramenta. A técnica de medição direta é muito dispendiosa, além de ser suscetível à falhas por cau-

<sup>15</sup> A medição das falhas da ferramenta através do acabamento da superfície usinada é um exemplo de **medição indireta** *off-line*, pois a medição dos parâmetros de rugosidade é feita diretamente na peça. Tais parâmetros são posteriormente correlacionados com o estado da ferramenta de corte.

<sup>16</sup> **Modelos analíticos** são baseados em operações matemáticas. Já os **modelos empíricos** baseiam-se na experimentação ou observação da realidade.

sa das condições de usinagem atuantes na máquina-ferramenta (e.g. cavacos, meio lubri-refrigerante etc.). Por outro lado, a medição indireta utiliza parâmetros que são relativamente fáceis de mensurar, mas os recursos computacionais envolvidos são caros [11; 47; 52].

A tabela 5.1 apresenta os principais métodos de medição do estado da ferramenta de corte em torneamento [4; 5; 8; 12].

**Tabela 5.1** – Exemplos de métodos de medição direta e indireta

Método	Procedimento	Medição	Transdutor (Sensor)
DIRETO	Óptico	Contorno ou posição do gume (região desgastada).	Câmera CCD; sensor de fibra óptica; microscópio.
	Perda volumétrica global da ferramenta	Tamanho e concentração de partículas desprendidas da ferramenta no cavaco.	Análise via radioatividade: espectrofotômetro e cintilador; análise eletroquímica.
	Resistência da junção	Alterações na resistência elétrica da junção ferramenta-peça.	Voltímetro
	Tamanho da peça	Dimensão da peça.	Micrômetros; transdutor: óptico, pneumático, ultra-som, eletromagnético.
	Distância ferramenta-peça	Distância entre a peça e a ferramenta ou suporte.	Micrômetro; transdutor indutivo (LVDT <sup>17</sup> ), capacitivo ou ultra-som.
INDIRETO	Força de usinagem	Alterações no comportamento da força.	Dinamômetros: piezelétricos ou resistivos ( <i>strain-gage</i> ); sensor de torque no eixo-árvore.
	Emissão acústica <sup>18</sup>	Ondas de deformação plástica.	Transdutor piezelétrico.
	Som	Ondas acústicas.	Microfone.
	Vibração	Oscilações da ferramenta e/ou suporte.	Acelerômetro piezelétrico.
	Temperatura	Variação da temperatura na região de corte.	Termopar; pirômetro; reflexão da superfície do cavaco ou sua coloração.
	Potência	Potência ou corrente consumida no motor (avanço ou rotação).	Amperímetro; sensor de corrente; sensor de potência.
	Acabamento da superfície usinada	Mudanças na rugosidade da superfície.	Rugosímetro; laser; métodos ópticos: sensor de fibra óptica, câmera CCD.

A classificação admitida à tabela 5.1 é relativamente complicada. Por exemplo, se o desgaste da ferramenta precisa ser determinado, uma alteração dimensional na peça [53],

<sup>17</sup> LVDT = *linear-variable differential transformer*.

<sup>18</sup> Apesar das exceções, a frequência de trabalho do sensor de vibração situa-se geralmente entre 20 Hz e 20 kHz; a de ultra-som fica na faixa de 20 kHz a 100 kHz; e a de emissão acústica entre 100 kHz e 1,0 MHz [13; 147].

considerada na tabela como um procedimento direto, também deveria ser considerada como um procedimento indireto nesta medição.

Diversos sensores especialmente projetados para o propósito de monitoramento de máquinas, ferramentas e/ou processos estão disponíveis no mercado, preenchendo diferentes requisitos tais como: confiabilidade, custo, repetitividade, facilidade de instalação e robustez [9; 13; 54; 55].

### 5.1.1 *Medição Direta*

Nos métodos diretos de sensoriamento do estado da ferramenta de corte, a quantificação das falhas (desgastes e avarias) é feita diretamente na ferramenta. A séria restrição a esses tipos de sistemas é que a medição direta, por limitações tecnológicas e funcionais, não pode ser realizada em tempo real, ou seja, a operação de corte é interrompida, somando-se assim os tempos de parada e mensuração ao tempo de produção. A vantagem principal sobre a medição indireta é que geralmente os métodos diretos têm maior confiabilidade pois só dependem do parâmetro medido [47].

Os transdutores (sensores) utilizados neste método de medição apresentam em geral custo mais elevado. Dentre eles, os sistemas ópticos destacam-se por fornecerem como resposta (variável de saída) uma grandeza métrica (tabela 5.1). Em geral, estes sistemas dependem fortemente das propriedades reflexivas da região de desgaste (ou avaria), em comparação com a superfície da ferramenta nova, para que se possa extrair os parâmetros morfológicos que caracterizem as falhas da mesma [10; 56; 57].

No presente trabalho, o método direto de monitoramento das falhas da ferramenta aplicado na "aquisição do conhecimento" (vide Capítulo 8) utiliza um sistema óptico de medição de forma e/ou posição do gume através de uma **câmera CCD** (*charge couple device*) digital. Ela se caracteriza pela flexibilidade de medição, elevada resolução, boa precisão e boa exatidão. Devido ao ambiente impróprio e como já dito acima, esses transdutores só podem ser utilizados entre ciclos de corte [58].

### 5.1.2 *Medição Indireta*

Por causa das desvantagens inerentes dos métodos de medição direta atualmente empregados, especialmente nas aplicações em chão-de-fábrica, os métodos de medição indireta têm sido investigados nos últimos anos [9; 11]. Pesquisas têm sido conduzidas ten-



tando encontrar possibilidades de mensurar parâmetros que se correlacionem diretamente com as falhas da ferramenta.

Os métodos indiretos de monitoramento baseiam-se no fato de que o estado da ferramenta de corte está associado a um grande número de fenômenos físicos, relacionados com o material usinado, o tipo de ferramenta, as condições do processo etc., e que estes fenômenos podem ser detectados através de sensores que, posicionados em locais estratégicos da máquina, qualificam indiretamente as falhas, principalmente pelos sinais de força, potência, emissão acústica, vibração ou ultra-som gerados no torneamento [9; 11; 13].

A aquisição de sinais é realizada por transdutores que fornecem um sinal elétrico de baixa intensidade em resposta a alguma grandeza física adquirida. Para o monitoramento da ferramenta, técnicas indiretas de sensoriamento tais como **força de usinagem**, **vibração** e **emissão acústica** são usualmente aplicadas. Teoricamente, estes sinais contêm a informação necessária para distinguir os diferentes estados do processo de usinagem e/ou da ferramenta de corte [59]. O Capítulo 6 trata com detalhes as três técnicas citadas.

### 5.1.3 Aplicação de um Sensor

De forma a se ter alta confiabilidade e robustez no monitoramento do estado da ferramenta em torneamento, tanto sistemas mono quanto multisensórios, combinados com diversas técnicas de processamento de sinais e reconhecimento de padrões, têm sido investigados nas últimas décadas para identificação de um ou mais tipos de condições da ferramenta (trinca, fratura, quebra do cavaco, desgaste etc.) [60–67]

Diferentes pesquisadores consideram a aplicação de um único sensor suficiente em sistemas de monitoramento onde é possível extrair dos sinais captados por este características estatisticamente independentes [65; 68; 69].

Sob o ponto de vista da utilização das informações coletadas, o arranjo mais potencialmente econômico para o monitoramento do estado da ferramenta, segundo Niu *et al.* [65], consiste na aplicação de um único sensor na identificação de múltiplas condições da mesma. Para tanto, é preciso que: (a) os dados dos sinais sensórios que caracterizam diferentes condições sejam coletados de maneira contínua e exata; (b) os métodos avançados de processamento de sinais possibilitem a extração de características distintas; (c) as técnicas de reconhecimento de padrões de alto desempenho representem e identifiquem de maneira confiável as múltiplas condições da ferramenta.

DIMLA *et al.* [70] mostram que o uso de um só sensor no desenvolvimento de sistemas TCM é insuficiente no reconhecimento da natureza complexa e diversificada do processo de usinagem; concluíram que mesmo quando são coletadas informações de baixa qualidade das diferentes fontes de sinais, a fusão destas informações ainda assim produzirá melhores resultados que se um único sinal sensório fosse usado. SICK [12] discorda parcialmente, afirmando que a aplicação de múltiplos sensores pode sim produzir resultados piores que a com um só sensor se as influências das condições de corte forem desprezadas.

#### 5.1.4 Aplicação de Múltiplos Sensores

A aplicação de métodos indiretos requer modelos preventivos apropriados que relacionem o parâmetro de interesse (falha da ferramenta) à variável detectada (sinais sensórios) [71]. Os sinais mensurados indiretamente são geralmente afetados pelas variações no material da peça, pela geometria da ferramenta e pelas condições de corte [28]. Dessa maneira, exige-se que estas variáveis sejam consideradas num sistema de monitoramento *on-line* do estado da ferramenta de corte [70].

Como os sinais gerados por apenas um sensor são tipicamente insuficientes para fornecer a informação cabível ao monitoramento do processo e da ferramenta, propôs-se para a aquisição de dados a utilização simultânea de diferentes sensores, posicionados em diferentes locais da máquina-ferramenta. Sinais de diferentes fontes são integrados para fornecer a máxima informação, necessária às tarefas de monitoramento [72–74]. Assim, esta técnica torna-se atrativa, desde que a perda de sensibilidade de um domínio sensório possa ser compensada pela informação captada por um outro sensor [28]. A estratégia de integrar múltiplas informações aumenta a precisão e viabiliza a análise das incertezas geradas na investigação do estado da ferramenta, já que a representação baseada nas características extraídas dos sinais e a tomada de decisão possibilitam um enriquecimento das informações adquiridas pelos diferentes sensores [75; 76].

Seja qual for a designação –  **fusão de sensores, integração de sensores, sensoriamento combinado** –, o objetivo é extrair mais conhecimento sobre as características do sistema atuante (máquina-ferramenta-peça), ao invés de simplesmente coletar mais dados sobre o processo de usinagem [46].

Nos trabalhos de J. M. LEE *et al.* [74] e L. C. LEE *et al.* [77], duas técnicas de monitoramento indireto se sobressaem por sua alta sensibilidade e são as mais indicadas para serem aplicadas simultaneamente na fusão de sinais sensórios em sistemas de monitoramento do estado da ferramenta: as componentes da força de usinagem e a emissão acústica.

DORNFELD [78] mostra que esta fusão mostra-se atrativa em dois segmentos: **informações complementares** e **riqueza de informações**.

### (a) Informações complementares

A perda de sensibilidade na informação sobre o estado da ferramenta por um sensor pode ser compensada se informações confiáveis são obtidas pelos outros sensores. De acordo com GHASEMPOOR *et al.* [79], a magnitude da força de usinagem é completamente sensível às condições de corte ( $v_c$ ,  $f$  e  $a_p$ ). Assim, quando há uma mudança significativa nestas condições, os sensores de emissão acústica podem complementar os de força, já que estes podem não fornecer dados corretos sobre o estado atual da ferramenta.

### (b) Riqueza de informações

Informações significativas podem ser extraídas ou sintetizadas a partir de diferentes fontes, facilitando o sucesso da detecção de falhas na ferramenta de corte sobre uma extensa faixa de parâmetros do processo. A fusão desses sinais proporciona dados relacionados com efeitos microscópicos (ondas de tensão no sensoriamento de emissão acústica) e macroscópicos (vibração no sensoriamento de força).

## 5.2 Condicionamento de Sinais

Uma parcela significativa da dificuldade de se aplicar o conhecimento científico às tecnologias de sensoriamento em chão-de-fábrica está no alto nível de ruído de diversas naturezas do ambiente industrial. Os transdutores (ou sensores) utilizáveis precisam ser robustos e ter boa resposta para enfrentar as condições severas dos processos envolvidos. Dessa forma, os sinais elétricos gerados pelos transdutores a partir dos sinais adquiridos precisam ser devidamente configurados (**condicionamento**) por problemas de saturação e distorção, visando gerar características altamente sensíveis às condições de usinagem [54]. Este condicionamento (também chamado de pré-processamento) é feito em duas etapas: etapa analógica e etapa digital.

### 5.2.1 Pré-processamento Analógico

O pré-processamento analógico atua na preparação dos dados antes da sua digitalização. A utilização de dispositivos processadores de sinais digitais (DSP – do inglês *Digital Signal Processors*)<sup>19</sup> tem sido amplamente difundida nos últimos anos e pesquisas têm levado a arquiteturas cada vez mais arrojadas. Porém, em aplicações nas quais é necessário processar sinais analógicos, os DSP's precisam de conversores analógico-digitais (ADC – do inglês *Analog to Digital Converters*) para o pré-processamento destes sinais. Em um sistema analógico controlado por computador, o sinal digital de resposta gerado deve ser alterado novamente por conversores digital-analógicos (DAC – do inglês *Digital to Analog Converters*), como mostra a figura 5.4.




Figura 5.4 – Pré-processamento digital de sinais analógicos [80]

A maioria dos transdutores (sensores) em uso no monitoramento de grandezas tais como força, vibração, emissão acústica, temperatura etc. geram sinais elétricos analógicos de tensão. Estes sinais precisam ser condicionados antes de serem enviados para o ADC, isto é, precisam ser configurados na etapa analógica de modo a torná-los compatíveis com os níveis que o ADC pode processar através de dispositivos apropriados. Em casos específicos, o pré-processamento de sinais analógicos pode ser mais eficiente se feito antes da conversão para sinal digital (fundamental para preservar a informação contida nestes sinais).

Como sinais elétricos analógicos de tensão de saída dos transdutores apresentam em geral pouquíssima magnitude, os dispositivos pré-processadores de sinais analógicos dispõem de amplificadores. Esta amplificação pode melhorar a precisão e a exatidão da informação contida no sinal, permitindo com isso um aumento da resolução e da sensibilidade da medição, visando a conveniente interpretação da tensão elétrica pelo ADC.

O uso de dispositivos pré-processadores de sinais analógicos localizados próximos dos transdutores possibilita uma melhora no sinal coletado por medi-lo antes que este seja muito afetado pelos ruídos do ambiente. Mesmo assim, estes dispositivos apresentam filtros para a rejeição destes ruídos, indesejáveis em uma certa faixa de frequência. Na maioria dos

<sup>19</sup> Esta etapa consiste no modelamento e na tomada de decisão do sistema de aquisição.

casos, ficam abaixo de 60 Hz (originários da rede elétrica ou das máquinas). Desta forma, utiliza-se um filtro passa-altas<sup>20</sup> (FPA) com função específica de provocar a máxima rejeição destes ruídos. Outro uso comum dos filtros é para prevenir o efeito *aliasing*<sup>21</sup> na conversão do sinal analógico para digital. Este efeito de distorção do sinal pode ser facilmente evitado pela remoção de qualquer componente de frequência do sinal que esteja acima da metade da frequência de amostragem usando filtros passa-baixas (FPB) antes do ADC [81].

### 5.2.2 Pré-processamento Digital

A aplicação do pré-processamento digital tem aumentado muito, principalmente com a evolução da informática (*hardware* e *software*). Um exemplo típico é a utilização de filtros digitais (e.g. filtros passa-altas FPA ou passa-baixas FPF) atuando sobre as perturbações<sup>22</sup> (ruídos) dos *hardwares* (analógicos ou digitais) ou sobre a influência de condições de corte nos sinais sensórios. Exemplos de aplicação são a linearização da curva característica do sensor ou a análise do comportamento do sinal sensório no processo de usinagem via modelagem matemática<sup>23</sup>. As informações requeridas podem ser obtidas por sensores adicionais, por uma base de dados ou ainda pelo CNC da máquina-ferramenta.

A maioria das publicações utiliza diretamente o sinal analógico digitalizado para extrair as características significativas do sinal, ou seja, sem o pré-processamento digital. LIU E ALTINTAS [82] descrevem o uso de filtros (FPA ou FPF) com o intuito de reduzir a influência de ruído ou outras perturbações que não devam ser mensuradas. Contudo, SILVA *et al.* [83] mostram que, mesmo sendo relativamente fáceis de implantar, os filtros digitais não têm demonstrado eficiência na redução de perturbações e podem remover informações vitais dos sinais coletados. Assim, deve-se analisar cuidadosamente a aplicação de filtros digitais na caracterização das informações extraídas dos sinais usados em TCM.

---

<sup>20</sup> O **filtro passa-altas** (FPA) deixa passar frequências altas sem alteração, causando uma redução de amplitude e um atraso de fase em baixas frequências. Já o **filtro passa-baixas** (FPB) faz o contrário.

<sup>21</sup> O efeito *aliasing* gera frequências adicionais quando o sinal de entrada contém frequências acima da "Frequência de Nyquist" (metade da frequência de amostragem).

<sup>22</sup> **Perturbações** ⇒ entradas (conhecidas ou não) que atuam no sistema, desviando temporariamente seu estado.

<sup>23</sup> Modelos analíticos no nível de pré-processamento digital do sinal sensório são calculados através de técnicas chamadas *hard-computing*, enquanto que os algoritmos usados na geração dos modelos de falhas da ferramenta são obtidos por técnicas denominadas *soft-computing*, mais conhecidas como inteligência computacional.

### 5.3 Tratamento de Sinais

Após o condicionamento, um tratamento refinado é realizado para extrair as informações dos sinais com a máxima confiabilidade. Isto caracteriza o processo de identificação de falhas da ferramenta, já que os sinais captados são usados por um sistema discriminante de informações com o intuito de representar a condição da ferramenta ou outro fator desejado [70]. A tarefa de identificação usualmente envolve em seu estágio preliminar o processamento dos sinais adquiridos através de análises estatísticas ou espectrais, visando a extração de características e a geração de **índices de monitoramento** [12; 16; 84]. Dependendo do sinal, diferentes técnicas de processamento podem ser aplicadas (fig. 5.5).

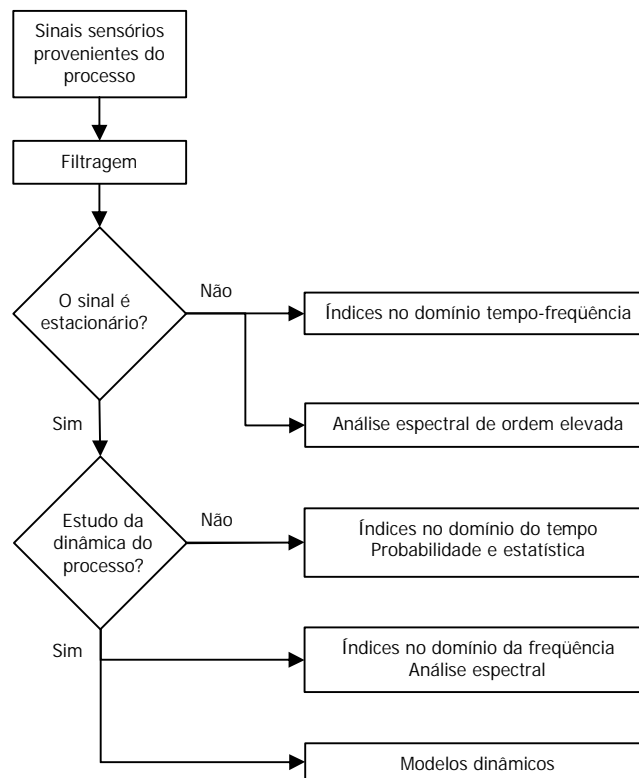


Figura 5.5 – Diretrizes para o processamento de sinais sensórios [84].

Em geral, os sinais sensórios são não-estacionários<sup>24</sup>, mas podem ser considerados como estacionários durante intervalos de tempo reduzidos na determinação dos índices [12].

<sup>24</sup> Seja um sinal sensório  $x(t)$ . Se sua média  $\mu(t)$  não depende do tempo  $t$  e sua variância  $\sigma^2(t_1, t_2)$  é função somente da diferença de tempo  $|t_1 - t_2|$ , então o sinal é chamado **estacionário**. Caso contrário, é denominado **não-estacionário**. Sinais estacionários são muito mais facilmente interpretados [198].

Du *et al.* [84] mostram como regra geral que se o sinal for estacionário e estático, ele pode ser caracterizado através da distribuição no domínio do tempo. Já se o estudo da dinâmica do processo for necessária, utiliza-se da análise espectral no domínio da frequência. Caso o sinal seja não-estacionário (devido à não-linearidade e/ou dependência do tempo no processo), ele pode ser analisado por meio de espectros de ordem elevada e/ou distribuição no domínio tempo-frequência simultaneamente.

Na prática, é muito difícil decidir pelo número de informações atuantes num diagnóstico. A abordagem mais prática e sensata para a minimização de erros preventivos é tomar um número pequeno de características e gradualmente aumentar esse número. Contudo, tal aumento dificulta a implementação de um sistema baseado em “regras”. Uma abordagem utilizando redes neurais artificiais parece ser mais aceitável quando a rede pode ser re-treinada a partir de exemplos [23; 69].

A experiência humana é muito importante na seleção das informações extraídas dos sinais. Para uma maior eficácia do sistema, o ideal seria trabalhar somente com variáveis independentes de entrada, ou seja, a situação em que cada informação refletiria sua propriedade física por si só sem poder ser substituída por outra [69]. Além disso, as características extraídas devem ser o mais independentes possíveis das condições de corte [14; 15; 68].

Além das características extraídas dos sinais sensórios, modelos de desgastes e avarias que geralmente baseiam-se nas condições de corte (informações específicas do processo) e/ou no tempo de vida da ferramenta (informações temporais) podem ser considerados como entradas do sistema [12].

### 5.3.1 *Extração de Características no Domínio do Tempo*

Para sinais sensórios no domínio do tempo, os mais comuns índices de monitoramento usados são a média ( $\mu$ ) e a variância ( $\sigma^2$ ), duas características estatísticas<sup>25</sup>. Se uma amostra do sinal  $\{x(i), i = 1, 2, \dots, n\}$  é coletada num intervalo de tempo “ $\Delta t$ ”, a média e a variância do sinal podem ser aproximadas, respectivamente, pelas equações (5.1) e (5.2).

O sinal “ $x$ ” será considerado estacionário quando forem calculadas a média e a variância de uma segunda amostra  $\{x(i'), i' = k+1, k+2, \dots, k+n\}$  no mesmo intervalo “ $\Delta t$ ” usando as equações (5.1) e (5.2), e forem obtidos praticamente os mesmos valores para as amostras 1 e 2.

---

<sup>25</sup> A média aritmética, a média quadrática e a assimetria são medidas de **tendência central**, enquanto que o desvio-padrão, a variância e a curtose são medidas de **dispersão** [89].

$$\mu_x = \frac{1}{n} \sum_{i=1}^n x(i) \quad (5.1)$$

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n [x(i) - \mu_x]^2 \quad (5.2)$$

Os sinais sensórios são tipicamente variáveis aleatórias contínuas, ou seja, podem assumir um conjunto contínuo de valores. Portanto, as características extraídas dos sinais podem ser descritas como funções de densidades de probabilidades. A distribuição de probabilidades pode ser representada graficamente, mediante a localização da probabilidade “p(x)” em relação à variável aleatória “x”.

As características extraídas no domínio do tempo são usadas, na maioria dos casos, em sinais de força. Publicações citam, por exemplo: as mudanças no nível do sinal (acréscimo ou decréscimo) [82; 85]; as relações entre as componentes da força de usinagem [25; 85]; o cálculo da média aritmética ( $\bar{X}$ ) ou quadrática (RMS) da magnitude do sinal em intervalos de tempo determinados [25; 85; 86].

Na geração de índices de monitoramento baseando-se na média quadrática, considera-se a distribuição do sinal em função do tempo. O valor  $x_{RMS}$  de “n” pontos coletados num intervalo de tempo “ $\Delta t$ ” pode ser calculado conforme a equação (5.3) [87; 88]:

$$x_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i)]^2} \quad (5.3)$$

Um caso especial de distribuição uniforme usualmente aplicada na análise estatística dos sinais é a distribuição beta ( $\beta$ ), cuja função é definida na literatura [89]:

$$\beta(a, b) = \int_0^1 x^{a-1} (1-x)^{b-1} \quad (5.4)$$

Esta função se caracteriza por apresentar a seguinte densidade de probabilidades:

$$p(x) = \begin{cases} \frac{(a+b-1)!}{(a-1)!(b-1)!} x^{a-1} (1-x)^{b-1} & \text{para } 0 \leq x \leq 1 \\ 0 & \text{para } x < 0 \text{ ou } x > 1 \end{cases}$$

onde “a” > 0 e “b” > 0.

A média e a variância da distribuição- $\beta$  são calculadas respectivamente pelas equações (5.5) e (5.6).



$$\mu_{\beta} = \frac{a}{a+b} \quad (5.5)$$

$$s_{\beta}^2 = \frac{a \cdot b}{(a+b)^2(a+b+1)} \quad (5.6)$$

Assim, os parâmetros "a" e "b" podem ser calculados em função da média e da variância, respectivamente pelas equações (5.7) e (5.8).

$$a = \mu_{\beta} \left[ \frac{\mu_{\beta}(1-\mu_{\beta})}{s_{\beta}^2} - 1 \right] \quad (5.7)$$

$$b = (1-\mu_{\beta}) \left[ \frac{\mu_{\beta}(1-\mu_{\beta})}{s_{\beta}^2} - 1 \right] \quad (5.8)$$

Os trabalhos de NIU *et al.* [29] e de JEMIELNIAK E OTMAN [90; 91] representam quantitativamente os valores dos parâmetros de assimetria<sup>26</sup> ( $S_{\beta}$ ) e curtose<sup>27</sup> ( $K_{\beta}$ ) da distribuição- $\beta$ , respectivamente através das equações (5.9) e (5.10):

$$S_{\beta} = \frac{2(b-a)}{a+b+2} \sqrt{\frac{a+b+1}{a \cdot b}} \quad (5.9)$$

$$K_{\beta} = \frac{6[(a-b)^2(a+b+1) - a \cdot b \cdot (a+b+2)]}{a \cdot b \cdot (a+b+2)(a+b+3)} \quad (5.10)$$

JEMIELNIAK E OTMAN mostram que a amplitude do sinal de emissão acústica ( $EA_{RMS}$ ) não se altera significativamente no momento da quebra da ferramenta durante o corte interrompido, enquanto que  $S_{\beta}$  e  $K_{\beta}$  da distribuição- $\beta$  apresentam boa correlação com a detecção da fratura.

AR e ARMA (do inglês *auto-regressive* e *auto-regressive moving average*) são modelos paramétricos de auto-regressão que se utilizam de séries temporais para efetuar o processamento de múltiplos sinais [92; 93]. Apesar destes modelos serem trabalhados estatisticamente no domínio do tempo, eles são usados principalmente na detecção de sinais dinâmicos (transitórios) [94]. As vantagens destes modelos sobre os demais, segundo os pesquisadores, é o baixo custo computacional necessário. Este argumento não é muito forte, pois atualmente os processadores de sinais digitais são capazes de efetuar o tratamento dos da-

<sup>26</sup> **Assimetria** representa o grau de desvio ou afastamento da simetria de uma distribuição. Se  $S_{\beta}$  for negativo, o valor que é registrado com maior frequência (valor modal) é maior que a média, e vice-versa [89].

<sup>27</sup> **Curtose** é o grau de achatamento de uma distribuição. Quanto maior a dispersão de valores em relação ao valor médio, menor o valor de  $K_{\beta}$  [89].

dos adquiridos pelos sensores em tempo real – mesmo para grandes taxas de amostragem. Somente o sinal de emissão acústica (EA), que trabalha em altíssimas frequências, pode ser uma exceção a esta regra. Uma descrição completa da modelagem de sinais de EA via séries temporais auto-regressivas (AR) pode ser vista no trabalho de LIANG E DORNFELD [62].

Finalizando, Sick [12] afirma que as mudanças nos índices de monitoramento que são obtidos através de características estatísticas extraídas no domínio do tempo dependem – não muito e nem pouco – das alterações nos valores das falhas contínuas (desgastes) da ferramenta. Já as variações nas condições de usinagem influenciam significativamente nestes índices. SILVA *et al.* [83] explicam que embora os índices não apresentem uma relação evidente com a evolução dos desgastes, percebe-se que não é possível julgar a importância destas características nos sistemas TCM devido à complexidade do processo de usinagem.

### 5.3.2 Extração de Características no Domínio da Frequência

A representação de um sinal proveniente de um transdutor (sensor) através da soma das senóides ou exponenciais complexas, comumente chamada representação Fourier<sup>28</sup>, é vantajosa na análise de sinais dinâmicos, pois serve para enfatizar certas propriedades pouco claras no sinal original (domínio do tempo) [78].

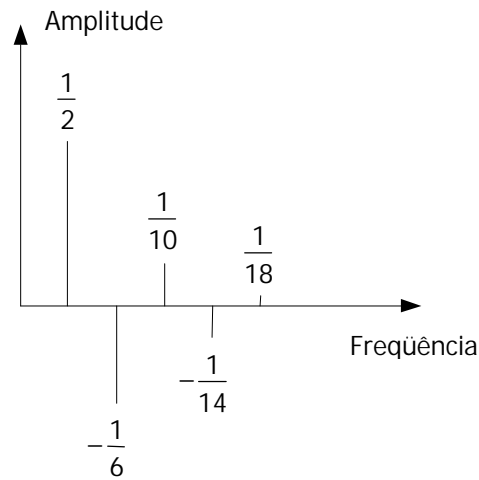
A transformada de Fourier (FT – *Fourier Transform*) possui a capacidade de analisar matematicamente um sinal estacionário dinâmico no domínio do tempo através do seu espectro de frequências. A essência da FT é decompor ou separar a forma de onda no domínio do tempo em um somatório de senóides de diferentes frequências (harmônicas). Quando este somatório de harmônicas representar a função original, tem-se determinada então a representação da função no domínio da frequência [95]. Uma representação típica da FT é um diagrama que mostra a amplitude e frequência de cada senóide do espectro (fig. 5.6).

A transformada de Fourier (FT) efetua primeiramente a translação da função (forma de onda) no domínio do tempo para uma função no domínio da frequência. Assim, o sinal pode então ser analisado pelo seu conteúdo em frequência pois os coeficientes da FT representam a contribuição de cada função seno e co-seno para cada frequência [96]. Isto pode ser um inconveniente quando se deseja descrever componentes transitórias, como a queda

---

<sup>28</sup> O matemático francês JEAN-BAPTISTE JOSEPH FOURIER (1768-1830) introduziu em 1822 a expansão de funções nas séries trigonométricas (seno e co-seno) chamadas *séries de Fourier* na obra intitulada *Theorie Analytique de la Chaleur* [198].

abrupta das componentes de frequência e a incapacidade de transferir apropriadamente todas as informações na translação entre os domínios tempo e frequência [97; 98].



**Figura 5.6** – Representação típica da Transformada de Fourier. Diagrama representando amplitude e frequência de cada senóide [95]

A transformada rápida de Fourier (FFT) é um algoritmo computacional que calcula o espectro de frequências dos dados adquiridos [14; 26; 99]. As séries temporais e a análise espectral por FFT são as técnicas de processamento de sinais mais comumente usadas na detecção de falhas transitórias na ferramenta. Contudo, as limitações estão na produção de boas soluções no domínio da frequência e fracas soluções no domínio do tempo devido à perda de algumas informações do sinal na transição tempo-frequência. Por isso, são usadas no processamento de sinais aleatórios estáveis [100].

Os índices de monitoramento tipicamente extraídos com a FFT são: (a) nível de potência total do sinal com ou sem uma componente estática e (b) potência em diferentes faixas espectrais. O nível de potência total pode também ser computado no domínio do tempo (Teorema de Parseval<sup>29</sup>). A potência nas faixas espectrais adjacentes é bastante usada pois é possível encontrar regiões no espectro que são, simultaneamente, sensíveis aos desgastes da ferramenta e independentes das mudanças nas condições de corte [15]. Com o intuito de minimizar o número desses índices (para evitar sobretraining na rede neural na etapa de generalização – detalhes no Capítulo 7), reduzir os efeitos de dispersão e ainda considerar as mudanças nas faixas espectrais, é necessário fazer um ajuste relativo na largura e no

<sup>29</sup> O Teorema de Parseval ilustra a propriedade da conservação da energia, isto é, a potência contida na representação do sinal no domínio do tempo é igual à energia contida na representação do mesmo sinal no domínio da frequência [198].

número destas faixas. Uma solução alternativa apresentada por MONOSTORI [27] mostra que a frequência do pico mais alto do espectro (ou parte dele) pode ser usada como entrada de um modelo de desgaste, juntamente com a potência da faixa espectral ao redor deste pico.

### 5.3.3 Extração de Características no Domínio Tempo-Frequência

A análise de Fourier é mais eficiente no estudo de sinais estacionários aleatórios estáveis. Se o comportamento não-estacionário de um sinal sensório é dependente do tempo, então a distribuição tempo-frequência passa a ser aplicada. Este tipo de distribuição pode ser visto como uma transformada que representa a energia ou a densidade do sinal nos domínios do tempo e da frequência simultaneamente. Recentemente, a análise de *wavelet* tem se apresentado como uma alternativa para a determinação de índices de monitoramento no domínio tempo-frequência.

A **Transformada de Wavelet (WT)** tem sido proposta como uma nova ferramenta para analisar o sinal monitorado de falhas na ferramenta, especialmente quebra [100] e desgaste de flanco [97; 101], na análise de vibrações auto-excitadas [97; 101; 102], e para decompor o sinal dinâmico da força de usinagem [23; 68], da emissão acústica [103; 104] e de ondas ultra-sônicas [1] em diferentes faixas de frequência no domínio do tempo. No trabalho de NIU *et al.* [65], a WT trabalha como um filtro, em que um único sinal sensório de emissão acústica é usado tanto na tarefa de detecção de avarias quanto de desgastes da ferramenta. ALEXANDER E GOR [105] apresentam uma aplicação alternativa da WT no monitoramento, diagnóstico e controle de processos industriais discretos e contínuos. KAMARTHI E PITTNER [106] mostram que, diferente da FFT, alterações do sinal em pequenos intervalos de tempo causam grandes alterações nos coeficientes de *wavelets*.

Resultados analíticos e experimentais têm mostrado que os métodos de monitoramento baseados na análise WT podem extrair informações do processo com parâmetros de descrição provenientes dos sinais brutos da força de usinagem (estático e dinâmico) e detectar o desenvolvimento do desgaste de flanco de maneira mais eficiente, mais confiável e mais rápida que pela FFT [97].

A mais interessante diferença entre FT e WT é que as WT não apresentam uma única classe de funções básicas como a FT, que utiliza apenas as funções seno e co-seno. Ao invés disso, a WT possui infinitas possibilidades de funções básicas [107]. Desta forma, a análise de *wavelet* proporciona acesso imediato às informações que poderiam ser ofuscadas por outros métodos tempo-frequência, como a análise de Fourier [96]. Com isso, a principal

desvantagem da FT (soluções apenas no domínio da frequência) pode ser superada pela WT através da solução sincronizada tanto no domínio do tempo quanto no domínio da frequência, podendo com isso extrair mais informações no domínio do tempo em diferentes faixas de frequência [68; 106]. Isto possibilita a formação de um sistema 3D *versus* o plano 2D tempo-frequência da FT, permitindo com que a WT seja capaz de capturar informações não-estacionárias (variação da frequência e/ou magnitude da oscilação) que a FT não consegue [101]. O trabalho de KAMARTHI E PITTNER [106] compara a utilização das transformadas rápidas de Fourier (FFT) e de *wavelet* (FWT) no tratamento de sinais de força (três componentes) e vibração, visando estimar (com ajuda de uma rede neural recorrente) a largura da marca de desgaste de flanco em torneamento. Como resultado, a FWT mostrou melhores resultados com os sinais de força enquanto que a FFT com os sinais de vibração. Contudo, ambas podem ser usadas na estimativa de valores contínuos de desgaste em tempo real.

Apesar de tudo, a supremacia desta técnica sobre as demais ainda não foi comprovada, já que nenhuma das publicações apresentadas aqui mostra uma comparação satisfatória das características extraídas dos sinais via WT com as obtidas por outras técnicas.

### 5.3.4 Seleção das Características

Os índices de monitoramento escolhidos representam de uma forma compacta as características extraídas que são sensíveis às falhas da ferramenta. Para SICK [12], o número de características deve ser grande o suficiente para representar qualquer aspecto relevante à classificação ou estimativa de desgastes e à detecção de avarias e pequeno o suficiente para evitar um sobre-treinamento da rede neural artificial.

RANGWALA E DORNFELD [15] afirmam que embora o aumento do número de características extraídas dos sinais sensórios geralmente aumenta o desempenho do sistema inteligente, em alguns casos, este aumento promove a deterioração deste desempenho. Uma possível explicação para o fato é que os dados estatísticos de treinamento e teste podem ser para uma característica em particular muito diferentes. Além disso, relatam a importância da escolha de características que independam das condições de usinagem.

HONG *et al.* [68] recomendam que se comece com um número reduzido de características e que se aumente gradualmente este número. Indicam também a necessidade de mais amostras de treinamento da rede com o aumento do número de características.

Portanto, a escolha das características será um dos fatores mais significativos no desempenho do sistema inteligente completo [108].

## 5.4 Reação ou Tomada de Decisão

Após o processamento dos sinais, o estágio posterior utiliza-se das características geradas para refinar a tomada de decisão quanto ao estado resultante da ferramenta e assim, auxiliar no diagnóstico de falhas [70]. O estado da ferramenta pode ser caracterizado através de duas formas de representação [16; 99; 109]: baseada em **modelos** e baseada em **padrões**. A primeira é expressa através de valores quantitativos, obtidos a partir da modelagem e/ou simulação do processo (por exemplo, a saída do sistema pode ser a largura da marca de desgaste VB – vide fig. 3.2). A segunda se dá pela classificação do estado da ferramenta (e.g. afiada, normal ou desgastada) através do reconhecimento dos padrões de falha usando limites estáticos ou dinâmicos, padrões de referência, redes neurais artificiais, lógica nebulosa ou ainda sistemas híbridos de inteligência artificial.

Como mostrado no início do presente capítulo, a representação do estado da ferramenta de corte num sistema inteligente de monitoramento deve ser expressa através da classificação por reconhecimento de padrões de falha (baseado em características) usando algoritmos de inteligência computacional para o processamento de informações e aquisição do conhecimento (aprendizagem). Com o intuito de tomar a decisão certa (promover a correta classificação), os algoritmos de aprendizagem devem ser desenvolvidos. Tais algoritmos ajustam seus parâmetros de aprendizagem baseando-se em amostras observadas das informações extraídas dos sinais correspondentes aos diferentes estados da ferramenta.

Como modelo inteligente, a rede neural artificial destaca-se por ser capaz de integrar as múltiplas informações captadas ao mesmo tempo pelos diferentes sensores, enquanto que o sistema nebuloso pode basear-se nos resultados gerados pela rede para fornecer uma representação estruturada da incerteza (tipo de falha) e com isso prever com uma boa margem de segurança a situação momentânea da ferramenta [76]. A figura 5.7 mostra um exemplo de representação da incerteza feita por HANS-JÜRGEN ZIMMERMANN [110].

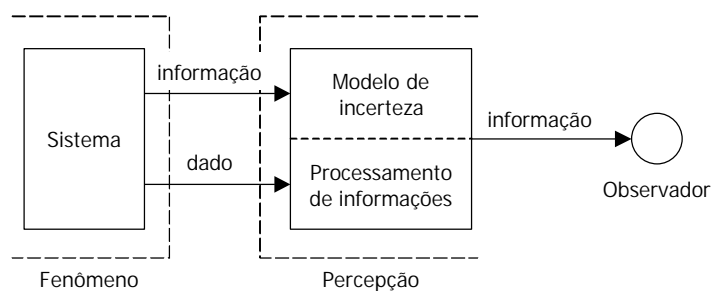


Figura 5.7 – Representação da incerteza [110]

Conforme a figura, tem-se que a escolha de um modelo apropriado de incerteza depende: (a) das causas de incerteza ou fenômeno observado; (b) da quantidade e da qualidade da informação disponível na entrada; (c) do tipo de processamento de informações requerido pelo respectivo modelo para avaliar os dados e/ou as informações; (d) da linguagem adequada da informação ao observador final (homem ou máquina) [110].

A seguir, far-se-á uma discussão sobre as técnicas de reconhecimento de padrões e algoritmos de inteligência artificial, comumente aplicadas em sistemas inteligentes para monitoramento de ferramentas de corte em processos de usinagem.

### 5.4.1 Reconhecimento de Padrões de Falha

O ser humano possui habilidades únicas de reconhecer padrões. Estas habilidades estão diretamente relacionadas com a capacidade cerebral de identificar, isolar, associar e reconhecer formas, sons ou outras sensações. A evidente complexidade destas habilidades (sentidos, memorização, combinação e avaliação) tem conduzido cientistas a tentar explorá-las e também incentivado pesquisadores a desenvolver metodologias computacionais que possibilitem imitá-las.

A filosofia de implementação de qualquer metodologia de sensoriamento visando o diagnóstico e/ou o monitoramento do processo para o reconhecimento de padrões de falha pode ser dividida em duas abordagens: **classificação** e **modelagem**.

- ☑ **Classificação**: quando o sinal de saída apresentar alguma relação característica com o processo de torneamento e as falhas resultantes na ferramenta de corte, define-se o comportamento do sinal sensório perante a situação "normal" do processo considerado (ferramenta nova). Se o sinal monitorado desviar-se do padrão considerado "normal", tem-se uma provável falha (ferramenta velha).
- ☑ **Modelagem**<sup>30</sup>: determina-se um modelo que seja capaz de relacionar a saída do sensor com a mecânica do processo. Então, com a informação fornecida pelo sensor, utiliza-se o modelo para prever o comportamento do processo.

Ambas são úteis em circunstâncias distintas. Talvez a primeira seja mais direta, objetiva, mas infelizmente está sujeita a interpretações errôneas caso ocorra alguma alteração no processo que não esteja prevista na classificação "normal-anormal". Assim, algumas es-

---

<sup>30</sup> Etapa da análise de um sistema, na qual são definidos os recursos, itens de dados e suas inter-relações.

estratégias são necessárias, como os **limites (estáticos e dinâmicos)** e os **padrões de referência**. Tais estratégias funcionam bem com eventos discretos (avarias), mas é complicado aplicá-las em alterações contínuas (desgastes) do processo. As variações nas propriedades do material, nas condições de corte etc. podem mascarar a relação do desgaste da ferramenta com as características extraídas dos sinais ou, no mínimo, limitar a faixa de aplicabilidade ou requisitar um aprendizado (treinamento) extensivo. A técnica mais bem sucedida baseia-se na extração das informações dos sinais devidamente processados, removendo a influência das variáveis relacionadas ao processo (e.g. velocidade de corte) [9]. Neste caso, sistemas mais elaborados de processamento de sinais precisam ser aplicados.

### (a) Limites estáticos e dinâmicos

O sinal fornecido pelo sensor deve ser devidamente tratado para que se possam detectar indiretamente as perturbações do processo (no caso, as falhas na ferramenta). O método mais simples usado utiliza o nível mínimo estático de detecção, ou **limite estático** [9; 111]. O método trabalha da seguinte forma: se o limiar estabelecido é ultrapassado pelo sinal por causa de alguma alteração no processo, esta situação acusa a ocorrência de um desgaste avançado na ferramenta, ou a presença de fratura na mesma, ou ainda uma provável colisão. Este método pode ser efetivo na detecção de condições anormais grosseiras, mas pode ser adversamente afetado pelas variáveis dependentes do processo.

Como o limite estático pode ser aplicado somente quando as condições de usinagem são constantes (profundidade de corte, homogeneidade da dureza do material da peça etc.), a utilização do **limite dinâmico** é mais apropriada na maioria das situações [9; 111]. Neste caso, o sistema de monitoramento estabelece automaticamente o limite superior e o inferior a partir das parcelas estáticas e dinâmicas do sinal medido. Assim, se a solicitação estática ou a dinâmica da ferramenta aumenta, os limites que acompanham o sinal se adaptam em relação ao sinal medido de forma automática, como mostra a figura 5.8.




Figura 5.8 – Limite dinâmicos [9]



No entanto, a velocidade de adaptação dos limites ao sinal medido é limitada, de forma que estes não conseguem acompanhar os sinais numa variação muito rápida (como na detecção de fratura). Conseqüentemente, tem-se a passagem acima do limite superior, seguida pela passagem abaixo deste, fazendo com que os limites sejam congelados a partir do instante anterior. Se na seqüência tem-se a passagem abaixo do limite inferior congelado, o alarme é disparado, indicando a quebra da ferramenta (fig. 5.9a). Se o sinal medido permanecer acima do limite superior por um tempo predefinido, o alarme indica que houve lascamento (fig. 5.9b). Isto mostra que estratégias específicas permitem que se possa distinguir entre quebra e lascamento de uma ferramenta, em que ambas apresentam uma variação muito rápida do sinal, mas levam a conseqüências distintas [2].




Figura 5.9 – Detecção da fratura em duas situações distintas [111]

O reconhecimento da quebra é extremamente rápido, de forma que num intervalo de apenas 5 ms o sistema de monitoramento pode emitir um sinal para a parada dos acionamentos de avanço da máquina-ferramenta com CNC aberto.

### (b) Padrões de referência

Os padrões de referência comparam o sinal “real” adquirido num certo intervalo de tempo com um sinal “ideal” previamente armazenado. O sistema armazena uma quantidade de dados de referência (padrão “ideal” do sinal de força adquirido) que possam representar a fratura da ferramenta. A figura 5.10 ilustra dois exemplos: quebra de uma ferramenta de metal-duro e de cerâmica [13; 112]. O comportamento da quebra de uma ferramenta de metal-duro mostra o crescimento abrupto do sinal de força seguido de uma queda rápida a zero. Na ferramenta de cerâmica, a subida não se verifica: ocorre apenas a queda do sinal.

A detecção da fratura através de padrões de referência tem a vantagem de não depender da magnitude do sinal resultante do processo. Assim, o sistema pode ser otimizado para ignorar as alterações no processo que não têm relação com o estado da ferramenta

(e.g. dimensão da peça, material da peça, parâmetros de corte etc.) [13]. A desvantagem deste tipo de estratégia é que um ciclo de “treinamento” é necessário para se armazenar o sinal “ideal”. Além disso, o fato de que os sinais precisam ser armazenados indica que mais memória é necessária ao sistema [10].

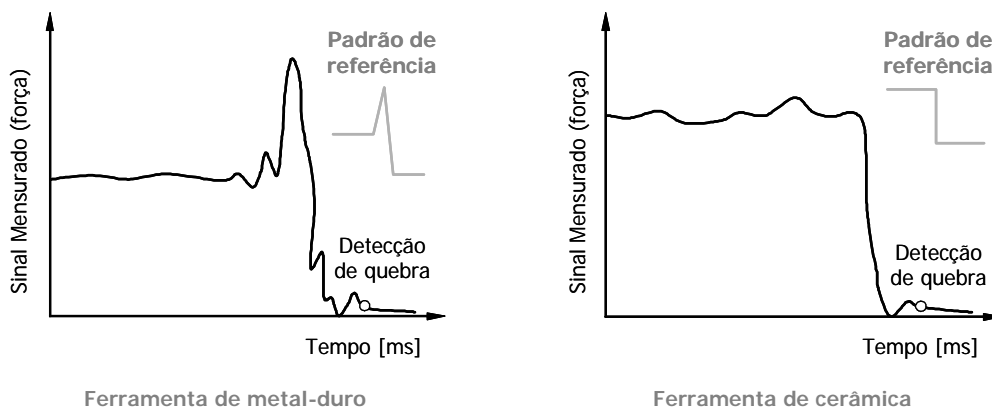


Figura 5.10 – Padrões de referência na detecção da fratura da ferramenta [13; 112]

#### 5.4.2 Inteligência Computacional (Soft Computing)

Os algoritmos de aprendizagem em inteligência computacional podem ser **simbólicos**, baseando-se na idéia de que os processos de percepção e conhecimento podem ser modelados (adquirir, manipular, associar e modificar representações simbólicas) ou **sub-simbólicos**, trabalhando com valores numéricos [113; 114].

Devido à natureza numérica do monitoramento do estado da ferramenta de corte em tempo real, relativamente poucos trabalhos foram realizados na aplicação de técnicas de aprendizado simbólica neste campo (como por exemplo os trabalhos de JIAA E DORNFELD [115] e parte do trabalho de Du *et al.* [116]), em comparação com a abordagem numérica.

Dentre os modelos numéricos mais conhecidos para a representação da incerteza, talvez a teoria dos conjuntos nebulosos seja o mais tradicional para o tratamento da informação imprecisa e vaga. Já o conexionismo<sup>31</sup> é a principal linha de pesquisa da inteligência artificial (IA) sub-simbólica (numérica) e tem por objetivo investigar a possibilidade de simulação de comportamentos inteligentes através de modelos baseados na estrutura e funcionamento do cérebro [117].

<sup>31</sup> Outros nomes usados para o domínio: redes neurais ou neuronais, processamento paralelo distribuído, sistemas neuromórficos, redes adaptativas, neurocomputação, computação coletiva e computação biológica [117; 119].



**Tabela 5.3** – Propriedades fundamentais dos métodos de conhecimento

Métodos de Conhecimento	Propriedades					
	IC	RI	RE	IT	GE	AP
Reconhecimento de padrões (RPD).	<b>M</b>	<b>B</b>	<b>M</b>	<b>B</b>	<b>M</b>	<b>B</b>
Redes neurais artificiais (RNA).	<b>A</b>	<b>M</b>	<b>M</b>	<b>B</b>	<b>M</b>	<b>M</b>
Sistemas neuro-nebulosos (SNF).	<b>A</b>	<b>M</b>	<b>A</b>	<b>M</b>	<b>M</b>	<b>M</b>

**Tabela 5.4** – Relação entre os métodos de conhecimento e suas aplicações

Domínio das Aplicações	Métodos de Conhecimento		
	RPD	RNA	SNF
Modelagem, monitoramento e controle.	<b>B</b>	<b>A</b>	<b>M</b>
Inspeção, diagnóstico e qualidade.	<b>B</b>	<b>A</b>	<b>M</b>

Na tabela 5.3, pôde-se ver claramente que os sistemas neuro-nebulosos (SNF) apresentam maior poder de representação das linguagens de informação (RE) e maior facilidade de interpretação do conhecimento (IT), em comparação com as redes neurais artificiais (RNA). Mesmo assim, as aplicações em modelagem, monitoramento, controle, inspeção e diagnóstico, são dominadas pelas RNA (tabela 5.4).


### (a) Redes Neurais Artificiais

Uma rede neural artificial (RNA) é um processador de informações baseado em modelos matemáticos que imitam as habilidades do sistema nervoso biológico a partir de um grande número de elementos de processamento (neurônios artificiais) simples intensamente interligados [119]. Este sistema computacional processa as informações através de uma resposta aos estímulos (entradas) externos. Assim, a estrutura de uma rede neural artificial é definida pela arquitetura de conexões entre os neurônios, pelas regras que determinam se um elemento de processamento irá disparar, e pelas regras que controlam as alterações nas relações (pesos) entre as interligações. Tal estrutura é gerada e modificada através do treinamento da rede [76].

A adaptação (ou capacidade de aprender) é uma das melhores características das redes neurais. Uma rede neural pode mapear um conjunto de padrões de entrada em padrões de saída simplesmente por exposição aos exemplos de mapeamento. Este procedimento, chamado de **treinamento**, permite a geração e a modificação gradual da rede atra-

vés da adaptação dos pesos que conectam os neurônios, aproximando os resultados obtidos pela rede daqueles que eram esperados [120].

As aplicações das redes neurais em usinagem e em sistemas de monitoramento do estado da ferramenta TCM têm sido reportadas desde 1987. Estes trabalhos demonstraram a viabilidade da utilização da RNA para integrar informações provenientes de múltiplos sensores visando monitorar os estados da ferramenta em usinagem. Foi relatado que os vários parâmetros na RNA deveriam ser cuidadosamente escolhidos para assegurar eficiência e ótimo desempenho do sistema TCM [14]. A maioria das aplicações envolve redes estáticas com processamento direto (sem realimentação), destacando as redes neurais diretas (FFNN – do inglês *feed-forward neural network*). As redes tipo **perceptron de múltiplas camadas** (MLP – do inglês *multilayer perceptron*) apresentam uma das configurações mais bem sucedidas de redes tipo FFNN. As redes tipo MLP (exemplo na figura 5.11) são muito usadas em sistemas TCM na classificação dos diferentes estados de desgaste no flanco da ferramenta de corte durante a operação de torneamento [121; 122] e na estimativa dos valores de desgaste de flanco da ferramenta em processo [70].



**Figura 5.11** – Exemplo de uma rede neural artificial tipo MLP [118; 119; 123–126]

DORNFELD [14] aplicou redes neurais artificiais (RNA's) em sistemas de monitoramento do estado da ferramenta. Uma série de testes foi feita num torno na usinagem de material endurecido de forma a induzir rápidas falhas na ferramenta. Foram captados sinais de emissão acústica e força durante o corte. Foi demonstrada a aplicabilidade das RNA's na fusão de sensores. Os resultados mostraram um esboço de melhoria na supressão de ruídos e na habilidade de classificação das redes neurais com a aplicação de funções lineares e algoritmos de treinamento por retropropagação (BP – *back-propagation*).

Com o propósito de detectar falhas na ferramenta, redes de tamanho relativamente pequeno trabalharam bem. Em muitos trabalhos publicados, uma RNA de arquitetura simples (três camadas) foi empregada. O número de neurônios de saída selecionado foi dois (ferramenta normal e quebrada, desgastada e afiada, etc.). Foram usadas redes diretas com algoritmos de treinamento BP [24; 25; 27; 70; 123–126]. Esta estrutura simplificada pode tornar possível a aplicação de RNA em sistemas de monitoramento do estado da ferramenta de corte na indústria.

## (b) Lógica Nebulosa

A lógica nebulosa LNB (do inglês *Fuzzy Logic*) permite o tratamento de expressões que envolvam variáveis lingüísticas descritas de forma não exata, isto é, apresentem falta de clareza e incertezas. Cinco causas de falta de clareza podem ser consideradas: imperfeição, não-determinismo, múltiplos significados, incerteza (estatística) e incerteza não-estatística. A nebulosidade é uma incerteza não-estatística e a lógica nebulosa lida com ela [16].

O tratamento de expressões que envolvem variáveis lingüísticas pode ser realizado através da utilização da lógica nebulosa que, por sua vez, se baseia em conceitos de conjuntos nebulosos [127; 128].

Um conjunto é uma coleção de objetos. Na teoria clássica, um objeto possui apenas duas possibilidades quanto à sua relação com um conjunto: pertence ou não-pertence. Na teoria dos conjuntos nebulosos, um objeto possui variados graus de pertinência [128].

Os conjuntos nebulosos foram introduzidos inicialmente por LOFTI A. ZADEH (Universidade da Califórnia – Berkeley, EUA) em 1965, com a intenção de modelar informações imprecisas e vagas do cotidiano [117; 128; 129]. A teoria de conjuntos nebulosos proporciona um mecanismo para representar conceitos lingüísticos tais como “muito”, “pouco”, ou “quase”, e um meio para mensurar o grau de um padrão presenciado ou a situação ocorrida.

Em termos específicos, os conjuntos nebulosos têm por objetivo modelar os modos imprecisos do raciocínio, que desempenham papel importante na habilidade humana de tomar decisões em ambientes incertos. Esta habilidade depende da capacidade de inferir respostas a uma questão baseada num conhecimento armazenado, cuja fonte é imprecisa ou não-confiável [120]. A simplificação na aquisição do conhecimento e o uso de variáveis lingüísticas possibilitam que se aproxime do pensamento humano [127].

A figura 5.12 mostra o conceito de estratégia nebulosa para tomada de decisão. Nesta,  $A_H$  e  $B_H$  são duas categorias classificadas pela decisão complexa (*hard-decision*), enquanto  $A_S$  e  $B_S$  são classificados pela decisão nebulosa (*soft-decision*). O *threshold* é usado

para a tomada de decisão complexa e forma uma interrupção abrupta no limite. A estratégia nebulosa para a tomada de decisão divide o espaço de classificação com “limites suavizados” contínuos [75; 76].




Figura 5.12 – Ilustração do conceito de estratégia nebulosa [75; 76]

A lógica nebulosa é uma extensão natural da lógica booleana clássica para números reais. Na álgebra de Boole, se **0** representar “falso”, **1** representará “verdadeiro”, sem outras possibilidades. Já na LNB, embora os extremos sejam interpretados da mesma maneira que na lógica booleana, todas as frações entre **0** e **1** existem e são empregadas para indicar graus variáveis de verdade [120].

Em manufatura, a LNB foi principalmente usada nas aplicações em estratégias de controle. Recentemente, padrões nebulosos foram introduzidos para descrever os estados do processo de corte em metais e do monitoramento do estado da ferramenta (TCM). A aplicação da lógica nebulosa no monitoramento de processos de fabricação é particularmente atrativa em situações em que mais de um estado da ferramenta resulta em alterações quase idênticas nas saídas dos sensores. Além disso, a lógica nebulosa oferece em sistemas TCM a vantagem de proporcionar meios sistemáticos para lidar com as incertezas inerentes ao processo, particularmente no delineamento da relação entre o estado da ferramenta e as diversas características do processo [75; 76].

A figura 5.13 ilustra um exemplo da aplicação das funções nebulosas de pertinência na classificação de desgastes da ferramenta. Observa-se que a vida da ferramenta foi dividida em cinco estágios de desgastes de flanco (VB): “inicial”, “normal”, “aceitável”, “severo” e “crítico”. As funções de pertinência foram estabelecidas baseando-se em dados empíricos e no comportamento do sistema. A forma trapezoidal foi escolhida devido à dificuldade de quantificar qual o percentual exato da largura da marca de desgaste corresponde a uma certa variável lingüística. No caso, quando  $VB = 283 \mu\text{m}$ , a ferramenta tem um grau de pertinência de 66% de desgaste “aceitável” e um grau de 34% de desgaste “normal”.

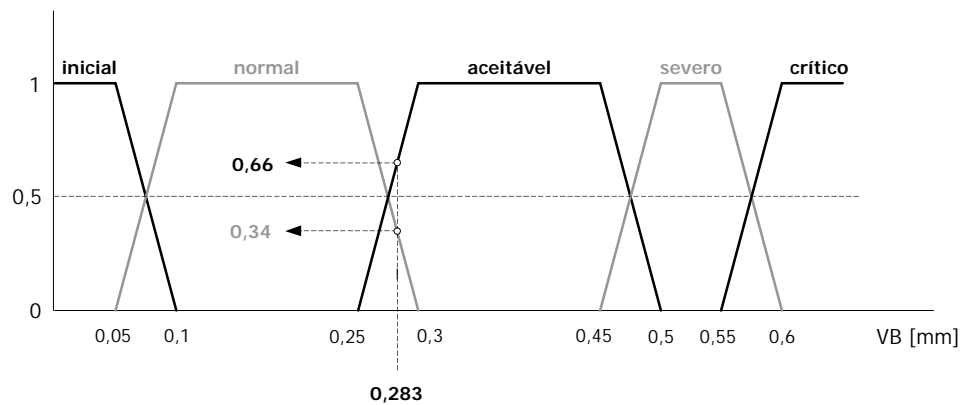


Figura 5.13 – Aplicação da lógica nebulosa na classificação de desgastes [26]

### (c) Sistemas Neuro-nebulosos

A combinação da lógica nebulosa com as redes neurais artificiais tornou-se interessante praticamente quando ambas puderam ser integradas nos projetos de sistemas inteligentes. As redes neurais artificiais proporcionam a possibilidade de intervir numa grande quantidade de dados sensórios simultaneamente usando elementos simples de processamento, e a lógica nebulosa fornece uma armação estrutural que se utiliza destes resultados de baixo nível (simplesmente processados) [75; 76].

Os sistemas neuro-nebulosos aliam a **capacidade de aprendizagem** das RNA's com a **facilidade de interpretação** dos sistemas nebulosos [12]. Embora haja muitas possibilidades de combinação entre tais técnicas, as quatro combinações mostradas na figura 5.14 têm sido aplicadas em sistemas atuais de produção [26].

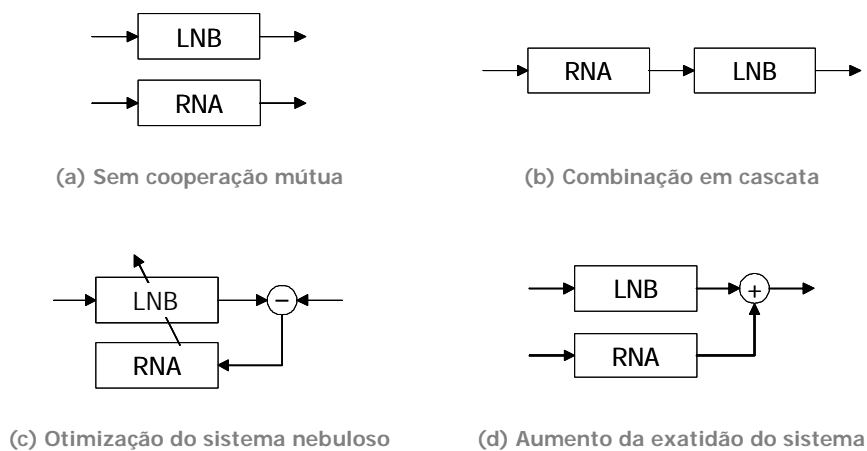
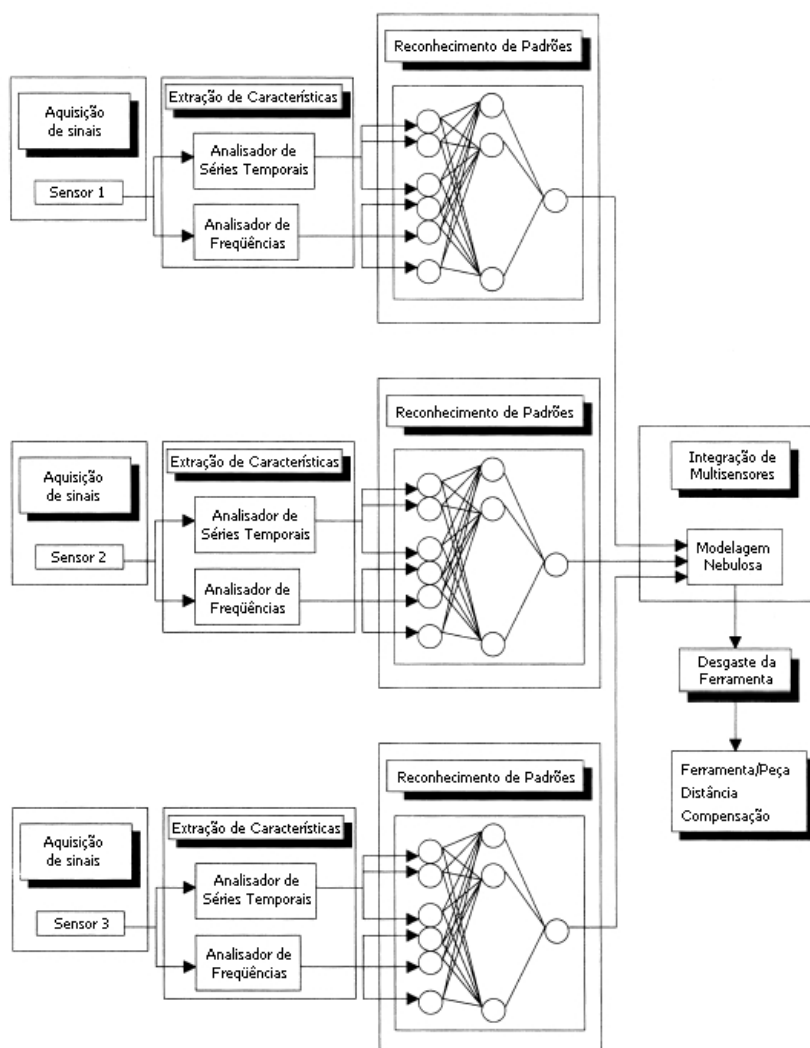


Figura 5.14 – Tipos de combinação entre RNA e LNB [26]



A figura 5.14(a) mostra o caso onde o dispositivo utiliza-se dos dois sistemas para propósitos distintos, ou seja, não há uma cooperação mútua. O modelo da figura 5.14(b) mostra a combinação em cascata entre RNA e LNB, onde a saída da rede neural torna-se a entrada do sistema nebuloso (poderia ser o inverso). A figura 5.14(c) utiliza a RNA para otimizar os parâmetros da LNB pela minimização do erro entre a saída da LNB e a especificação fornecida. Este esquema refere-se ao modelo combinado com aprendizado de rede, onde o sistema total é descrito através da LNB, mas os membros da LNB são produzidos e ajustados através do aprendizado da RNA [76]. A figura 5.14(d) mostra um modelo combinado com uma estrutura de igualdades, onde a saída da LNB é conectada à saída da RNA para aumentar a exatidão na saída do sistema [26; 76].

Os trabalhos de KUO E COHEN [130; 131; 132] mostram a aplicação de modelos nebulosos de auto-organização e auto-ajustamento (SOSAFM – *self-organizing and self-adjusting fuzzy model*) na estimativa dos valores de desgaste, como mostra a figura 5.15.



**Figura 5.15** – Aplicação do sistema SOSAFM na estimativa de valores de VB [130; 131; 132]

O sistema de monitoramento da figura 5.15 consiste de três redes neurais usadas no reconhecimento de padrões de desgastes, a partir das características extraídas (domínios do tempo e da frequência) dos sinais captados de força ( $F_x$ ,  $F_y$  e  $F_z$ ), vibração ( $VI_x$  e  $VI_z$ ) e emissão acústica (EA). O sistema SOSAFM faz a integração dos valores de desgastes estimados pelas três redes e toma a decisão baseando-se nas regras de inferência nebulosa no formato "IF-THEN".

#### (d) Comentários

O trabalho de BALAZINSKI *et al.* [133] descreve a aplicação das três técnicas de inteligência computacional citadas anteriormente (RNA – redes neurais artificiais, LNB – lógica nebulosa e SNF – sistemas neuro-nebulosos na estimativa dos desgastes da ferramenta de corte em torneamento a partir da extração de informações das componentes de avanço ( $F_r$ ) e passiva ( $F_p$ ) da força de usinagem. O valor de "VB" medido em função do tempo foi comparado com os valores estimados nas três técnicas. Em todos os casos, os resultados foram satisfatórios, indicando com segurança o fim de vida da ferramenta de corte. As diferenças entre os valores estimados para cada um dos métodos foram tão pequenas que não foi possível concluir qual é a melhor técnica a ser aplicada em TCM, como mostra a figura 5.16. Já as diferenças na utilização destas técnicas em chão-de-fábrica são bastante significativas.




Figura 5.16 – Comparação entre RNA, LNB e SNF na estimativa de VB [133]

Segundo os autores, a construção da base de conhecimento para uma LNB depende da habilidade e da experiência do operador, pois ele precisa saber analisar os resultados preliminares do monitoramento indireto do desgaste. Isto faz da LNB o sistema de implantação mais complexa. Na utilização de RNA, tanto o número de neurônios na camada oculta quanto o número de iterações (ciclos de treinamento ou *epochs*) podem ser selecionados

arbitrariamente, pois eles pouco influenciam no desempenho do sistema. Os resultados dos testes preliminares (dados de aprendizado) não precisam ser apresentados ao operador. Ao invés disso, ele simplesmente alimenta a entrada do sistema. A desvantagem da RNA está no longo período de treinamento (aprendizagem), que torna inconveniente sua implantação. Similarmente à RNA, a estrutura (número de regras) e o número de interações do SNF não têm influência significativa no desempenho do sistema. Também, o operador não precisa conhecer os resultados dos testes preliminares. A mais importante diferença entre RNA e SNF está no tempo de treinamento: no SNF, o tempo é tão curto que o método pode ser facilmente otimizado e implementado em chão-de-fábrica.

## 5.5 Sistemas de Monitoramento Comercializados

Apesar do grande número de publicações relativas ao monitoramento de ferramentas e/ou processos de usinagem, aplicando novos conhecimentos tecnológicos na aquisição e processamento de sinais, a aplicação de sistemas de monitoramento em ambientes industriais é muito reduzida, limitada e pouco confiável. Além disso, os ajustes destes sistemas para emprego em chão-de-fábrica são demorados, o que justifica sua função para produções seriadas (grandes lotes), em que os parâmetros de corte são muito pouco alterados.

VÖHRINGER [134] em seu trabalho diz que o objetivo dos sistemas comercialmente aplicados de reconhecer o desgaste excessivo através do monitoramento do estado da ferramenta de corte durante as operações de torneamento na fabricação seriada, visando evitar a quebra do inserto e paralisar a máquina-ferramenta imediatamente, tem sido alcançado com sucesso em poucos casos (nestes destacam-se as operações de desbaste, pois as operações de acabamento ainda requerem amadurecimento).

O desempenho do sistema depende: do tipo de transdutor aplicado; da precisão e da exatidão do sinal de resposta do transdutor; da natureza das variáveis dependentes do processo; e da técnica de processamento de sinais utilizada na análise do sinal sensório. A maioria dos sistemas comerciais utiliza a força de usinagem ou suas derivações (torque, momento torçor, potência ou corrente do motor) como grandeza a ser monitorada [135].

Muitas variáveis dependentes do processo de torneamento como: flutuações no lote de peças, variações no material bruto, variações de dureza na peça e operação de corte interrompido podem ter um impacto negativo na performance de um sistema de monitoramento. Estes fatores podem produzir variações nos sinais sensórios que são similares às alterações provocadas pelas falhas na ferramenta de corte. Quando isto acontece, poderá ha-

ver alarme falso pelo excesso de sensibilidade do sistema; ou a não detecção de falhas quando elas ocorrerem pela falta de sensibilidade do referido sistema.

Fabricantes como ARTIS, BRANKAMP, KISTLER, MONTRONIX, NORDMANN e PROMETEC utilizam na maioria dos casos apenas um único sinal sensório de força (geralmente a componente de corte) para a detecção da quebra da ferramenta, com tratamento baseado em filtragem, média e RMS. Além disso, a estratégia de detecção de falhas baseia-se quase sempre nos “limites estáticos”, em que se detecta uma anomalia quando o sinal ultrapassa os limites estabelecidos [13]. Mesmo com o desenvolvimento de estratégias mais sofisticadas de processamento de sinais, como os “limites dinâmicos” da PROMETEC, “reconhecimento de padrões” e “avaliador de desgastes” da MONTRONIX, somente a última utiliza-se da combinação de diferentes sinais captados simultaneamente (as componentes da força) para a detecção de falhas (mesmo assim, exclusiva para torneamento) [13]. A medição de dois ou mais eixos simultaneamente requer um dinamômetro mais sofisticado e caro, para que os efeitos negativos das variações do processo de torneamento possam ser minimizados.

Segundo LANGGUTT E WEBER [136], esta dependência entre os sensores empregados e o processamento dos sinais gerados mostra que uma melhoria no sensoriamento é apenas uma possibilidade de se ter um melhor resultado no reconhecimento de desgastes ou na detecção de avarias, já que a escolha dos sensores adequados a um determinado processo de usinagem deve ser feito em concordância com a estratégia de monitoramento empregada ou com o sistema de aquisição de dados (hardware).

Como tendência, KLUFT [2] afirma que os usuários de máquinas-ferramenta desejam cada vez mais dispor de um sistema único que seja capaz de monitorar simultaneamente a máquina, a ferramenta e o processo, para que se possa garantir facilidades de operação, treinamento e manutenção. Este fato impõe exigências severas à flexibilidade do sistema de monitoramento, pois este deve ser capaz de: (a) integrar-se a qualquer tipo de comando numérico computadorizado; (b) ser compatível com as interfaces de comando da máquina; (c) permitir a adição de diversos sensores; e (d) dispor de estratégias de monitoramento adequadas. A solução foi compor o sistema de monitoramento em módulos independentes.

O Capítulo 5 esmiuçou os elementos constituintes de um sistema de monitoramento aplicado na detecção de falhas na ferramenta de corte. Foi dito que informações significativas podem ser extraídas de diferentes fontes, facilitando esta detecção sobre uma extensa faixa de parâmetros do processo. Desta forma, o Capítulo 6 mostrará como é realizado o **Reconhecimento da Falha via Sinais Indiretos**.

## 6 - RECONHECIMENTO DA FALHA VIA SINAIS INDIRETOS



*“Para que se possa implementar um sistema eficiente de detecção automática de falhas em ferramentas de corte num ambiente de manufatura flexível, é necessário muito trabalho para avaliar as relações entre as variáveis envolvidas no processo e as falhas na ferramenta”.*

LI DAN E J. MATHEW

A partir de métodos indiretos de monitoramento, é muito difícil diagnosticar a real extensão do desgaste da ferramenta. Assim, o gradiente de variação da largura de desgaste médio de flanco (VB) com o tempo é muitas vezes adotado como critério de fim de vida para tais métodos [8; 77; 137]. Este baseia-se no fato do sinal detectado indicar uma alteração significativa na mudança do estágio de desgaste de “normal” (região secundária ou progressiva **BC**) para “acelerado” (região terciária ou catastrófica **CD**), mostrada na figura 6.1.




Figura 6.1 – Estágios de desenvolvimento do desgaste de flanco [40]

Muitos tipos de sensores e técnicas de processamento de sinais têm sido investigados para detectar ou prever o início do estágio acelerado de desgaste na ferramenta. O sensoriamento da força tem se destacado no monitoramento de falhas contínuas por sua alta

sensibilidade [8; 77]. Contudo, o sinal sensório representa uma combinação de diferentes fenômenos de desgaste. As contribuições de todas as regiões desgastadas (especialmente no flanco e na face) para o sinal sensório são muito diferentes. É muito difícil distinguir entre as várias contribuições e estimar o tipo de desgaste (embora YAO e FANG [137] tenham mostrado a estimativa dos diferentes tipos de desgaste usando sinais de força em condições de usinagem limitadas).

O processo de reconhecimento de padrões de desgaste em ferramentas de corte a partir de apenas dois estados (normal e desgastada) mostrou-se ineficaz em uma ampla faixa de condições de usinagem. A aplicação de redes neurais artificiais no processo de identificação, distinção e tomada de decisão de um número maior de padrões mostra-se adequada, pois assim é possível avaliar diferentes estágios de desgaste ao longo da vida da ferramenta [23]. Nos trabalhos desenvolvidos por Niu *et al.* [29; 65], por exemplo, o desgaste de flanco é dividido em três: **normal** ( $VB \leq 100 \mu\text{m}$ ), **gradual** ( $100 \mu\text{m} < VB < 300 \mu\text{m}$ ) e **intenso** ( $VB \geq 300 \mu\text{m}$ ).

No caso de avarias ou fraturas (falhas transitórias) na ferramenta, inúmeras razões podem estar a elas associadas: desgaste excessivo, choque mecânico, choque térmico, variações no material da peça etc. [1]. Segundo MORIWAKI [63], a detecção destas falhas é tão importante quanto a detecção de desgastes pelas seguintes razões: (a) as avarias apresentam natureza estocástica<sup>32</sup> (irregular, casual ou aleatória) e por isso são muito difíceis de prevenir ou detectar, em comparação com os desgastes, que possuem comportamento progressivo (regular); (b) as avarias podem causar danos catastróficos irreversíveis ao produto e por isso devem ser evitadas, ou seja, medições imediatas precisam ser efetuadas antes que elas aconteçam.

Assim, reconhece-se que o monitoramento *on-line* de falhas (desgastes e/ou avarias) é indispensável nas operações de usinagem com a mínima supervisão humana. Para isso, destacam-se os sinais de **força**, **vibração** e **emissão acústica**. Os sensoriamentos baseados (a) na potência e torque no motor de acionamento; e (b) na temperatura, merecem também destaque, mas num plano secundário.

---

<sup>32</sup> Um processo é dito **estocástico** quando envolve um fenômeno aleatório que evolui ao longo do tempo e que, de alguma forma, pode ser controlado por leis da probabilidade [89].

## 6.1 Força de Usinagem

A força de usinagem “F” é a força que atua sobre o gume durante a operação de corte. As suas componentes são obtidas mediante uma decomposição ortogonal, de acordo com as considerações tecnológicas e físicas da formação do cavaco [31]. A componente “F<sub>z</sub>” projetada sobre a direção de corte é a força de corte (F<sub>c</sub>); a componente normal à direção de corte “F<sub>x</sub>” projetada sobre a direção de avanço é a força de avanço (F<sub>f</sub>); a componente radial “F<sub>y</sub>” projetada perpendicularmente ao plano de trabalho é a força passiva ou de profundidade (F<sub>p</sub>). As componentes ortogonais da força de usinagem (F<sub>x</sub>, F<sub>y</sub>, F<sub>z</sub>) geradas no processo de torneamento podem ser esquematizadas através da figura 6.2.




Figura 6.2 – Componentes ortogonais da força de usinagem no torneamento [11; 31; 75; 76; 138; 139]

Equacionando:

$$F = \sqrt{F_f^2 + F_p^2 + F_c^2} \quad (6.1)$$

A determinação das componentes da força de usinagem sempre foi uma área importante, tanto na prática quanto na pesquisa, relativa às operações de corte com ferramentas de geometria definida. Nesta determinação, uma série de fatores deve ser considerada: máquina-ferramenta, material da peça, área da seção de corte, espessura de corte, geometria da ferramenta (ângulo de posição “ $\chi_r$ ”), estado da ferramenta, material da ferramenta, meio lubri-refrigerante, parâmetros de usinagem, temperatura na região de corte, ambiente de trabalho etc. [140].

KÖNIG E KLOCKE [19] afirmam que é possível verificar uma variação da influência do desgaste da ferramenta sobre as componentes da força “F”, dependendo do tipo. Por exem-

plo, o desgaste de cratera (o qual conduz a um ângulo de saída “ $\gamma$ ” mais positivo) pode produzir uma diminuição destas componentes. Se, no entanto, ocorrer um predomínio de desgaste de flanco, as forças tendem a aumentar, pois a área de contato entre a peça e o flanco aumenta. Já DIMLA [11] afirma que “ $F_f$ ” é insensível à formação da cratera e também que “ $F_p$ ” e “ $F_f$ ” podem ser mais influenciadas pelo desgaste que “ $F_c$ ”.

A medição da força de usinagem mostra-se eficaz na detecção de falhas transitórias no gume da ferramenta. Em geral, uma mudança brusca no nível de amplitude do sinal das componentes da força de usinagem indica lascamento ou quebra na ferramenta [5; 8; 141].

Existem dois diferentes pontos de vista sobre a fratura da ferramenta. O primeiro é baseado na evidência de que as componentes da força de usinagem inicialmente crescem devido aos fragmentos desprendidos da ferramenta serem comprimidos entre a ferramenta e a peça, e subseqüentemente declinam para zero. Além disso, lascamentos causam aumentos repentinos e permanentes nas forças de avanço ( $F_f$ ) e passiva ( $F_p$ ). O segundo ponto de vista adota a seguinte posição: tanto a força de corte ( $F_c$ ) quanto “ $F_f$ ” são sensíveis à fratura, mas somente “ $F_c$ ” exibe uma consistente mudança (decréscimo) de nível absoluto quando o gume quebra. A magnitude da queda na “ $F_c$ ” como consequência da fratura é proporcional ao comprimento fraturado ao longo do gume. O nível da “ $F_f$ ” pode aumentar ou diminuir, dependendo do grau e do tipo de lascamento [8; 11].

Algumas das limitações inerentes na abordagem destas componentes são as perturbações causadas pelas variações no material da peça, na velocidade de corte, na profundidade de corte e na geometria da ferramenta. Estas variações podem gerar a mesma ordem de magnitude que os diferentes níveis de desgastes e avarias em ferramentas de corte [77]. Por exemplo, pode-se observar uma redução das forças com o aumento da velocidade de corte ( $v_c$ ); isto se dá devido à redução da resistência do material em altas temperaturas. As forças aumentam proporcionalmente com a profundidade de corte ( $a_p$ ); entretanto, isto vale somente se “ $a_p$ ” for maior que o raio de quina ( $r_e$ ) da ferramenta (vide figura 2.4) [19].

Para eliminar a influência das variações das condições de corte, ferramentas e materiais da peça, YOUN E YANG [142] estabelecem a normalização das componentes da força de usinagem a partir das equações (6.2), (6.3) e (6.4).

$$\checkmark \text{ Avanço:} \quad NF_f = \frac{F_f}{F} \quad (6.2)$$

$$\checkmark \text{ Passiva:} \quad NF_p = \frac{F_p}{F} \quad (6.3)$$

$$\checkmark \text{ Corte:} \quad NF_c = \frac{F_c}{F} \quad (6.4)$$



Os sistemas sensórios mais usados para a determinação indireta do estado da ferramenta de corte tomam como base a avaliação das componentes da força de usinagem ou a medição das grandezas derivadas destas componentes (torque, potência do motor ou flexão da ferramenta). Todos eles partem do princípio de que o desgaste da ferramenta proporciona um crescimento das componentes estáticas da força [32; 143]. O trabalho de LEE *et al.* [77] mostra como regra geral que, para cada 100  $\mu\text{m}$  de acréscimo na região de desgaste de flanco, a força passiva ( $F_p$ ) aumenta 30%, a força de avanço ( $F_f$ ) cresce 25%, e a força de corte ( $F_c$ ) aumenta 10%. Segundo KÖNIG E KLOCKE [19], com uma marca de desgaste de aproximadamente 500  $\mu\text{m}$ , tem-se um aumento relativo de 100% na força passiva, de 90% na força de avanço e de 20% na força de corte.

NOVAK E WIKLUND [144] discutem se o monitoramento indireto via sinais de força pode ser totalmente fidedigno, afirmando que apesar das amplitudes das componentes crescerem com o aumento da largura da marca de desgaste de flanco (VB), elas são diretamente afetadas pelo desgaste de cratera, a qual promove a diminuição destas amplitudes.

Com intuítos diferentes (o primeiro de aumentar a confiabilidade do sistema de monitoramento do estado da ferramenta e o segundo de otimizar o processo de torneamento), LEE *et al.* [145] e SUKVITAYAWONG E INASAKI [146] efetuaram um estudo detalhado sobre diferentes combinações entre os valores das componentes da força de usinagem ( $F_f$ ,  $F_p$  e  $F_c$ ), destacando as relações  $R_1$  (bons resultados em ambos os trabalhos),  $R_2$  (bons resultados em TCM) e  $R_3$  (os melhores resultados em TCM).

$$R_1 = \frac{F_f}{F_c} \quad (6.5)$$

☑ Bons resultados em TCM:

$$R_2 = \frac{F_p}{F_c} \quad (6.6)$$

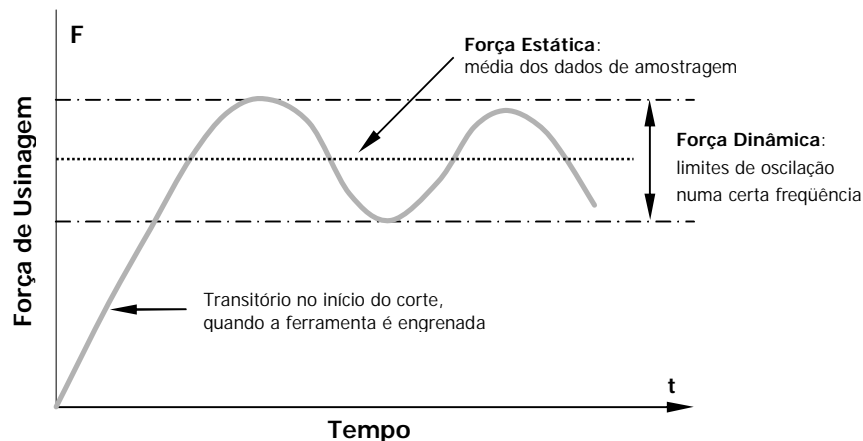
☑ Os melhores resultados:

$$R_3 = \frac{\sqrt{F_f^2 + F_p^2}}{F_c} \quad (6.7)$$

DAS *et al.* [24] também utilizam as relações " $R_1$ " e " $R_2$ " como entradas de uma rede neural.

LEE *et al.* [77] aplicam relações entre as componentes da força de usinagem com o argumento de que as influências do material da peça, da geometria da ferramenta etc. podem ser minimizadas. Infelizmente, isso é parcialmente verdade já que as condições de corte não podem influir em todas as componentes da mesma forma. Adicionalmente, os efeitos dos desgastes também podem ser mais ou menos reduzidos. No entanto, não só o aumento do desgaste, mas também as mudanças nas condições de corte têm uma influência significativa nos níveis dos sinais de força. Assim, a normalização passa a fazer sentido.

As componentes da força de usinagem durante a operação de corte podem estar muitas vezes sujeitas a alguma flutuação dinâmica ao longo do tempo por variações nos parâmetros de usinagem e/ou oscilações do sistema porta-ferramenta(s) (fig. 6.3). As duas principais causas são: instabilidade dinâmica provocada pela variação da velocidade da ferramenta com relação à velocidade da peça e a influência do achatamento da ponta da ferramenta com o desgaste na ação de corte [77].



**Figura 6.3** – Parcelas estática e dinâmica da força de usinagem em função do tempo de usinagem (condições fixas de corte) [11]

A aquisição de valores estáticos é feita conforme a descrição da extração de características no domínio do tempo (equação 5.1). Para as parcelas dinâmicas, considere uma amostra do sinal de força  $\{F(i), i = 1, 2, \dots, n\}$  coletada num intervalo de tempo  $\Delta t$ . Se  $F_{D(i)}$  representa a parcela dinâmica da força, e  $F_{S(i)}$  o valor amostrado, então:

$$F_{D(i)} = F_{S(i)} - \mu_F \quad (6.8)$$

onde " $\mu_F$ " é a média da amostra do sinal coletado no intervalo de tempo " $\Delta t$ " [122].

Na última década, estudos têm sido conduzidos sobre as parcelas dinâmicas das componentes da força de usinagem em torneamento. RAHMAN *et al.* [69] e DIMLA [122] utilizam a parcela dinâmica da força de avanço como o dado inicial para o diagnóstico do estado da ferramenta. HONG *et al.* [68] definem diferentes bandas de frequência no domínio do tempo do sinal dinâmico da força de usinagem como índices de monitoramento (extração de características). GONG *et al.* [97] mostram o monitoramento do desgaste de flanco através da análise das parcelas dinâmicas das componentes via transformada de *wavelet* (WT). GRABEC *et al.* [138] propõem um novo método para a detecção da vibração auto-excitada

(*chatter*) baseado na caracterização das mudanças na dinâmica do processo de torneamento, através da medição destas componentes. DIMLA e LISTER [121] utilizam-se da parcela dinâmica da força de usinagem e da vibração para associar as alterações dos sinais com as falhas da ferramenta, obtendo bons resultados na detecção dos desgastes de flanco e quina, em comparação com a detecção de entalhe.

Na aquisição de sinais de força, utilizam-se freqüentemente transdutores extensométricos resistivos (*strain-gage*), indutivos (LVDT) ou piezelétricos. Os dinamômetros compostos por cristais piezelétricos apresentam algumas vantagens sobre os demais transdutores de força, no que se refere a aplicações complexas em usinagem, já que para isso os equipamentos devem apresentar [19]: alta rigidez (1 a 10 kN/ $\mu\text{m}$ ); alta sensibilidade (resolução de aproximadamente  $10^{-3}$  N); alta freqüência natural (2,5 a 4,0 kHz); grande faixa de medição (cerca de  $1:10^6$ ).

## 6.2 Vibração

Durante o processo de usinagem, a deformação plástica e o atrito entre o cavaco, a ferramenta de corte e a peça produzem vibrações. As oscilações da força de corte também produzem vibrações. Com o decorrer do tempo de corte e com o conseqüente desgaste da ferramenta, o sinal de vibração apresenta alterações de freqüência e intensidade. Assim, conforme OHBA [147], a vibração (movimento ondulatório que se propaga através dos materiais sólidos) indica um fenômeno que varia com o tempo. Além disso, quando a vibração alcança a superfície do material, gera os deslocamentos chamados **Ondas de Rayleigh**.

As vibrações podem ser quantificadas em termos de movimento ondulatório (deslocamento, velocidade, aceleração); forma da onda (senoidal, randômica, de impulso); valor instantâneo; valor de pico (ou pico-a-pico); valor eficaz; período e freqüência; etc. A oscilação senoidal pode ser expressa através da equação (6.9):

$$y = y_0 \text{sen}(\omega t + \theta) \quad (6.9)$$

onde "y" é o valor instantâneo do deslocamento no instante "t"; "y<sub>0</sub>" é a amplitude de deslocamento; " $\omega$ " é a freqüência angular; " $\theta$ " é a fase.

Sabe-se através dos princípios da cinemática que a derivada do deslocamento em função do tempo é a velocidade "v", equação (6.10), e a derivada da velocidade em função do tempo é a aceleração "a", equação (6.11). Para uma amplitude de deslocamento "y<sub>0</sub>" fixa, a amplitude da velocidade de vibração "v<sub>0</sub>" cresce proporcionalmente com a freqüência

angular ( $\omega$ ), enquanto a amplitude da aceleração “ $a_0$ ” aumenta com o quadrado da frequência angular ( $\omega^2$ ), equação (6.12).


$$v = v_0 \cos(\omega t + \theta) = v_0 \sin(\omega t + \theta + \pi/2) \quad (6.10)$$

$$a = -a_0 \sin(\omega t + \theta) = a_0 \cos(\omega t + \theta + \pi/2) \quad (6.11)$$

$$a_0 = \omega \cdot v_0 = \omega^2 \cdot y_0 \quad (6.12)$$

Como mostradas em diferentes publicações, as vibrações mudam seu comportamento com os desgastes da ferramenta [8; 9; 11]. No caso das avarias (fraturas), um pico de sinal de vibração RMS é detectado num intervalo de tempo reduzido [141; 148]. Estas vibrações podem ser medidas com a utilização de transdutores do tipo acelerômetro piezelétrico (saída em volts), principalmente na aquisição de sinais com frequências entre 1 e 20 kHz.

A figura 6.4 ilustra os sinais de vibração da ferramenta adquiridos no presente trabalho para o mesmo gume após 1 minuto (novo) e após 14 minutos (desgastado).



**Figura 6.4** – Sinais de vibração da ferramenta de metal-duro no torneamento a seco do aço ABNT 1040 com  $f = 0,3$  mm,  $v_c = 350$  m/min e  $a_p = 1,5$  mm em tempos de vida diferentes

DINIZ E HARA [149] mostraram em seu trabalho que diferentes autores estudaram a relação entre a vibração e o desgaste da ferramenta com o intuito de verificar o fim de vida da ferramenta em operações de torneamento. A maioria dos resultados mostrou que o método é apropriado para satisfazer este propósito. Também afirmam que um dos principais problemas na utilização de índices de monitoramento baseados em sinais de vibração reside no fato de que estes não variam somente com o desgaste, mas também com os parâmetros de usinagem, geometria da ferramenta etc.

Segundo DIMLA [11], as inter-relações entre os sinais de vibração e a força de usinagem determinam a natureza dinâmica do processo, tornando a utilização destas variáveis

(dependentes) atrativa no desenvolvimento de sistemas de monitoramento do estado da ferramenta. Por outro lado, o comportamento dinâmico incorpora a vibração e certos aspectos da parcela dinâmica da força de usinagem. Assim, a fusão das características extraídas dos sinais de força e vibração no desenvolvimento de sistemas de monitoramento baseados em múltiplos sinais sensórios poderá se tornar indispensável em chão-de-fábrica.

### 6.3 Emissão Acústica

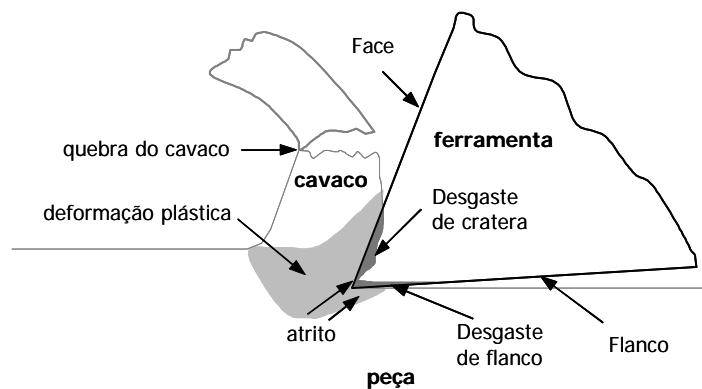
A utilização da emissão acústica no monitoramento de processos de fabricação tem sido discutida desde a sua descoberta na década de 50, na Alemanha [59]. Mesmo assim, sua primeira aplicação em máquinas-ferramenta ocorreu no Japão somente cerca de vinte anos mais tarde [7].

Diversos trabalhos definem a emissão acústica (EA) como sendo ondas de tensão elástica de baixa amplitude e alta frequência geradas por atuações dinâmicas sobre os materiais [150–154]. Conforme o material é submetido a um estímulo externo qualquer (como a formação de cavaco), o atrito entre ferramenta e peça ou mesmo o simples contato faz com que ocorra a deformação e a reordenação da estrutura cristalina do material. Isto libera uma quantidade de energia suficiente para produzir ondas de tensão que provocam mais deslocamentos sobre a superfície do mesmo (ondas *Rayleigh*) [150], os quais se atenuam exponencialmente à medida que se afastam da superfície para dentro do material.

Com relação à geração do sinal de emissão acústica (EA) durante o processo de corte em metais, as quatro principais áreas são [6; 59; 88; 152-158]:

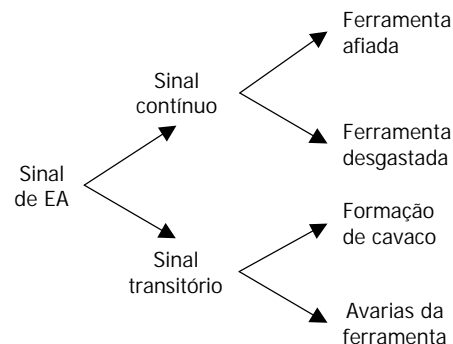
- ☑ **Zona Primária**, à frente da ferramenta, onde ocorre a deformação plástica principal durante a formação do cavaco com o cisalhamento do material;
- ☑ **Zona Secundária**, ao longo da face da ferramenta, onde acontece a maior taxa de deformação do cavaco na zona de escorregamento (atrito), gerando desgaste de cratera;
- ☑ **Zona Terciária**, no flanco da ferramenta, no atrito com a peça, gerando desgaste frontal;
- ☑ **Região de Fratura do Cavaco**, na formação de fragmentos descontínuos de material.

A figura 6.5 mostra as possíveis causas da geração de sinais de EA durante o processo de corte ortogonal em torneamento.



**Figura 6.5** – EA gerada no processo de corte [59; 88; 152; 153; 155; 157; 161]

A formação do cavaco (deformação plástica de materiais dúcteis), o desgaste de flanco e de cratera estão associados a sinais regulares contínuos de EA, enquanto que o rompimento do cavaco, o lascamento, o crescimento de trincas e a quebra da ferramenta associam-se a sinais transitórios de pico de alta amplitude e curta duração (fig. 6.6). [60; 65; 155-157; 159; 160].



**Figura 6.6** – Tipos de sinais de EA em processos de usinagem [156]

Na interface flanco-peça, o sinal de EA vai sofrendo alterações significativas conforme o desgaste vai aumentando, pois esta falha promove um crescimento do atrito na região de contato entre as duas superfícies, provocando um aumento do nível do sinal. Com isso, o monitoramento do sinal permite identificar diferentes níveis de desgaste [7; 150; 162]. Na interface cavaco-face, as alterações no ângulo de saída ( $\gamma$ ) poderiam ser controladas com auxílio do sinal de EA, uma vez que com o desgaste de cratera, " $\gamma$ " torna-se mais positivo, proporcionando uma diminuição no fator de recalque e a conseqüente redução do nível do sinal de emissão acústica [163]. Assim, se forem registrados desgastes no flanco e na face da ferramenta simultaneamente, poderá haver uma superposição de efeitos, como constatado por TETI [164].

Os parâmetros de corte têm influência decisiva sobre a intensidade do sinal de EA no monitoramento do estado da ferramenta de corte em operações de torneamento. O estudo realizado por BLUM E INASAKI [155] mostrou um crescimento da EA com o aumento da velocidade de corte, uma redução do sinal com o aumento do avanço e a indiferença do sinal às alterações na profundidade de corte (fig. 6.7).





Figura 6.7 – EA para diferentes velocidades de corte [16]

O aumento da velocidade de corte faz com que haja uma diminuição do fator de recalque, mas a quantidade de material deformado na unidade de tempo cresce, fazendo com que o sinal aumente de intensidade. Já o aumento do avanço faz com que esta ocorrência reduza, fazendo a EA também diminuir; esta diminuição pode ser associada ao comportamento da força de usinagem ( $F$ ), principalmente das componentes " $F_c$ " (corte) e " $F_f$ " (avanço). Assim, é preciso que se faça uma aferição do sistema de aquisição de sinais de EA para cada condição de usinagem utilizada dificultando, portanto, sua utilização.

Um modelo básico para a geração de sinais de EA durante o processo de corte ortogonal (zonas de deformação primária e secundária) foi proposto por K-ASIBU E DORNFIELD [161]; a formulação é baseada na teoria de corte ortogonal de ERNST E MERCHANT e estabelece uma dependência da energia de EA sobre as propriedades dos materiais, tais como: tensão de escoamento, volume de material submetido à deformação e taxa de deformação. Depois disso, os esforços em modelar EA a partir da deformação fundamentaram-se nesta abordagem [88; 153; 165; 166].

DORNFELD [59] afirma que nos processos convencionais de usinagem que utilizam ferramentas com geometria definida, a EA possibilita a detecção de desgastes e fraturas na ferramenta, falhas na lubrificação do processo, formação do cavacos e vibrações. O trabalho de BEGGAN *et al.* [167] mostra que a ocorrência desses fenômenos está relacionada aos seguintes defeitos que podem ser encontrados nas peças: acabamento superficial deficiente e variações dimensionais. Assim, com o uso da EA no monitoramento dos processos, os fenômenos citados poderiam ser evitados e, por conseguinte, os defeitos também.

Os sistemas que utilizam emissão acústica são capazes de detectar até microlascaamentos (alta sensibilidade), mas apresentam a limitação de serem eficientes somente em operações de corte contínuas (torneamento, furação). No corte intermitente (fresamento), o ruído induzido na operação perturba a discriminação fidedigna do sinal de emissão acústica sobre a avaria detectada [41]. Como já citado na seção 5.3.1 (extração de características no domínio do tempo), JEMIELNIAK E OTMAN [90; 91] mostram que os valores dos parâmetros de assimetria ( $S_\beta$ ) e curtose ( $K_\beta$ ) da distribuição- $\beta$  [equações (5.9) e (5.10)] têm boa correlação com a detecção da fratura (FCF – falha catastrófica da ferramenta), figura 6.8; vale dizer que a eficiência desta detecção depende principalmente do tamanho da amostra do sinal e do intervalo de tempo entre duas amostragens sucessivas.



**Figura 6.8** – Detecção da fratura a partir de  $K_\beta$  do sinal de EA no torneamento do aço 1045 usando ferramenta P30 com  $f = 0,33$  mm,  $v_c = 260$  m/min e  $a_p = 2,5$  mm [90]



Por se tratar de um sinal que se propaga tanto longitudinal quanto transversalmente na estrutura do material, a EA permite que o sensor seja colocado em qualquer posição, desde que em contato com o material e em uma localização onde não haja muitas interfaces que tendem a distorcer e enfraquecer o sinal, dificultando sua avaliação [150].

O sensoriamento dos sinais de EA se justifica pela alta sensibilidade ao material da peça, à geometria da ferramenta, aos desgastes da ferramenta e aos parâmetros de corte (p. ex: avanço e velocidade de corte) em diferentes condições de usinagem [152]. A principal vantagem deste sensoriamento está na supervisão de diversos fenômenos ocorridos simultaneamente durante o processo de corte, utilizando-se um único sensor, visto que os sinais de EA são excelentes para avaliar a existência de contato entre superfícies em movimento, o que ocorre de forma intensa na usinagem de metais [16].

## 6.4 Outros Métodos

Além dos três principais métodos descritos acima, outros métodos indiretos podem ser aplicados na detecção e estimativa dos desgastes e avarias na ferramenta de corte, no monitoramento ou na medição das variáveis dependentes (grandezas físicas associadas às falhas na ferramenta) geradas no processo de torneamento. Estes métodos considerados em segundo plano por suas características e limitações são: (a) corrente elétrica e potência no motor de acionamento e (b) temperatura.

### (a) Corrente elétrica e potência no motor de acionamento

A potência e/ou a corrente elétrica consumida pela máquina-ferramenta são proporcionais à potência mecânica consumida pelo processo e, com isso, proporcionais também à força de usinagem. Apesar de serem sistemas relativamente baratos (não necessitam de instrumentação adicional), as variações na potência e/ou torque do motor possibilitam detectar apenas falhas consideravelmente grandes [168; 169]. Para exemplificar, PIRES E DINIZ [170] realizaram um trabalho numa empresa metal-mecânica de usinagem média e pesada na qual verificaram que se podia evitar o desperdício de ferramentas de torneamento através da correlação entre o desgaste da mesma e o crescimento da corrente elétrica do motor de acionamento da máquina. No caso, pôde-se verificar a variação da corrente com o desgaste através de um amperímetro instalado na máquina. Com a aplicação, a porcentagem de gumes trocados antes do momento adequado caiu de 68% para 16,6% [22].

Alternativamente, o trabalho de STEIN E HUH [171] promove a estimativa da força de usinagem baseando-se na medição da corrente elétrica do motor de acionamento do eixo árvore e da rotação do mesmo.


## (b) Temperatura

Como já discutido no item 2.2.2.(e), o desgaste da ferramenta – e conseqüentemente o tempo de vida - está diretamente associado com a temperatura da ferramenta na região de corte. Esta grandeza física, embora seja um indicador extremamente confiável e desejável da situação de desgaste da ferramenta, é extremamente difícil de medir com a precisão e a exatidão necessárias em aplicações *on-line* de sistemas TCM por causa do difícil acesso à região de corte. Experimentos realizados há décadas mostram a excepcional dificuldade em aplicar o sensor na região de corte visando detectar a temperatura do gume [172].

No monitoramento indireto *on-line*, a aplicação de termopares isolados parece ser a única maneira viável de se medir a temperatura na interface ferramenta-peça. Tal aplicação dá-se somente nos casos onde a medição direta da distribuição de temperaturas não pode ser realizada [173]. Para que os termopares sejam usados no monitoramento, é necessário que forneçam medidas precisas e instantâneas de temperatura. Desta forma, eles devem ser colocados mais próximos possível do gume da ferramenta – onde está a fonte de calor. A forma mais usual de introdução do termopar dentro da ferramenta ou da peça implica em se fazer um pequeno furo na extremidade da ferramenta utilizando-se de métodos de usinagem não-convencionais ou furos simples em pontos da peça onde haja interesse da medida, acarretando descarte posterior da ferramenta ou da peça. Além disso, os termopares não podem ser colocados em contato direto com a ferramenta ou a peça quando uma e/ou outra estiver em movimento [174].

Outro método de medida de temperatura em sistemas TCM é através da medição da intensidade da radiação de infravermelho. Este método permite flexibilidade de posicionamento, coisa que os termopares não permitem. Além disso, a velocidade de resposta do termopar depende da velocidade de propagação do calor no meio, enquanto que a onda eletromagnética da radiação de infravermelho propaga-se na velocidade da luz [174]. Embora os sensores de radiação de infravermelho apresentem algumas vantagens sobre os de termopares, D'ERRICO [175] relata que faltam sensores infravermelho confiáveis, além do alto custo do equipamento. Por outro lado AY E YANG [176] descrevem que em suas medidas obtiveram exatidão de 1,0°C com o uso de sensores de infravermelho comparados com a exatidão de 1,4°C dos termopares.

Em seu trabalho, BORELLI [174] propõe uma metodologia para o diagnóstico de estados de ferramentas no processo de torneamento a partir de imagens de infravermelho captadas por uma câmera apropriada. O sistema de auxílio ao diagnóstico baseia-se na inferência nebulosa (LNB). Os tons de cinza – de “0” (preto) a “255” (branco) – apresentados nas imagens adquiridas são proporcionais à energia emitida pelo espectro de infravermelho e variam com o estado da ferramenta. A figura 6.9 ilustra tal variação.



**Figura 6.9** – Tons de cinza em função do desgaste da ferramenta P15 no torneamento do aço 1045 usando  $f = 0,50$  mm,  $v_c = 497$  m/min e  $a_p = 0,40$  mm [174]

O Capítulo 5 mostrou que após o processamento dos sinais usados na obtenção de informações confiáveis para o reconhecimento da falha (mostrados no Capítulo 6), o estágio posterior utiliza-se destas informações para refinar a tomada de decisão quanto ao estado resultante da ferramenta e assim, auxiliar no diagnóstico. Visando tomar a decisão correta, algoritmos de aprendizagem devem ser desenvolvidos. O Capítulo 7 mostrará a definição e a abordagem de um algoritmo de inteligência computacional aplicado em sistemas de monitoramento que se destaca principalmente pela sua capacidade de integrar múltiplas informações adquiridas ao mesmo tempo por diferentes sensores: as **Redes Neurais Artificiais**.

## 7 - REDES NEURAIS ARTIFICIAIS



*"Eu escuto e esqueço, eu vejo e lembro, eu faço e aprendo".*

PROVÉRPIO CHINES

As **redes neurais artificiais** (RNA's) constituem-se de paradigmas da computação estruturados para emular, em uma escala bastante simplificada, o processo biológico de aprendizado humano, com a intenção de simular a forma como o cérebro aprende, recorda e processa as informações.

Os computadores digitais e o cérebro humano resolvem tarefas de modos totalmente diferentes. Os primeiros superam o segundo na realização de cálculos matemáticos complexos, com rapidez e resultados precisos. Contudo, o cérebro humano tem a habilidade de reconhecer padrões (visual, auditivo, olfativo, tátil e palatal) e fazer inferência de modo a associá-los, o que excede em muito a capacidade dos computadores.

Assim, a idéia das RNA's é utilizar algoritmos computacionais inteligentes em implementações motivadas pela simulação das habilidades de aprendizado, processamento e generalização do cérebro humano, mesmo que rudimentarmente, já que o cérebro humano possui um sistema neural estimado em  $10^{11}$  neurônios biológicos no córtex, conectados num sistema altamente complexo de  $10^{14}$  a  $10^{15}$  conexões ou sinapses, cujo conhecimento é, até hoje, bastante limitado [177]. Em síntese, as redes neurais são normalmente aplicadas em situações em que as regras **se/então** são desconhecidas ou difíceis de compilar e/ou quando se pretende inferir resultados novos baseados na generalização de padrões já observados anteriormente [120].

HECHT-NIELSEN [178] definiu formalmente uma RNA como sendo uma estrutura que processa informação de forma paralela e distribuída e que consiste de unidades computacionais (que podem possuir uma memória local e podem executar operações locais) interconectadas por canais unidirecionais chamados de conexões. Cada unidade computacional (ou neurônio) possui uma única conexão de saída, que pode ser dividida em quantas conexões laterais fizerem-se necessárias. Cada uma destas conexões transporta o sinal de saída do

neurônio, o qual pode ser contínuo ou discreto. O processamento executado por cada neurônio pode ser definido arbitrariamente, com a restrição de que ele deve ser completamente local, isto é, deve depender somente dos valores atuais dos sinais de entrada que chegam até o neurônio via conexões e dos valores armazenados na memória local do neurônio.

## 7.1 Modelo de McCulloch e Pitts

De maneira demasiadamente simplificada, um neurônio biológico é formado por um corpo celular (ou soma) que contém o núcleo da célula, diversos dendritos (por onde os impulsos elétricos são recebidos) e um axônio (por onde os impulsos elétricos são enviados). A figura 7.1 mostra, esquematicamente, a estrutura de um neurônio biológico. As interligações entre os neurônios são efetuadas através das sinapses.




Figura 7.1 – Neurônio biológico


Em 1943, o neurofisiologista WARREN McCULLOCH e o matemático WALTER PITTS propuseram modelar o neurônio biológico como uma unidade computacional de limite lógico (do inglês TLU – *Threshold Logic Unit*). O funcionamento do modelo proposto pode ser descrito da seguinte maneira: sejam as entradas de natureza binária ("0" ou "1") de um neurônio; se a soma ponderada dos sinais de entrada ultrapassar um determinado limite de disparo, então a sua saída é alta (1); se não ultrapassar, é baixa (0) [128]. Os modelos atualmente usados para um neurônio artificial baseiam-se no modelo rudimentar de McCulloch e Pitts.

## 7.2 Estrutura Geral para Redes Neurais Artificiais

Existem vários modelos de RNA. Porém, cada modelo pode ser definido formalmente pelas seguintes características principais [128]:

- ☑ Conjunto de "n" neurônios, cuja atividade é representada pelas entradas " $x_i$ ".
- ☑ Função de saída para cada neurônio, ou seja, " $y_i=F(a_i)$ ".
- ☑ Padrão de conectividade entre os neurônios, definido pela matriz de pesos " $W$ ".
- ☑ Cálculo dos níveis de ativação " $a_i$ " (soma ponderada) dos neurônios de entrada.
- ☑ Regra de aprendizado usada para modificar o padrão de conectividade da rede, usando informação fornecida pelo ambiente externo (modificar a matriz de pesos " $W$ ").

A figura 7.2 mostra a estrutura geral do modelo de um neurônio numa RNA.



**Figura 7.2** – Estrutura geral de um neurônio artificial [119: 128: 177]

Cada uma das "n" entradas " $x_i$ " é multiplicada por um peso " $w_{ij} \in \mathfrak{R}$ ", que simula a conexão (sinapse) entre o neurônio "i" e o neurônio "j", gerando o nível de ativação " $a_i$ ". Quando estes não estão conectados, o peso assume valor zero. A este nível de ativação é aplicada uma função de ativação " $F(a_i)$ " que define a saída do neurônio em termos do nível de atividade de sua entrada, de maneira a produzir a saída do neurônio ( $y_i$ ).

O nível de ativação é definido pela equação 7.1:

$$a_i = \sum_{j=1}^n w_{ij} x_j + b_i \quad (7.1)$$

O valor de polarização ou limiar " $b_i$ " (*bias* em inglês) é usado para deslocar a função de ativação de modo a tornar um neurônio mais ou menos sensível. Isto garante que dois neurônios que recebem o mesmo nível de ativação não sejam necessariamente iguais.

Os neurônios de entrada são, de certa forma, hipotéticos, pois não realizam qualquer processamento; é nesta camada que os dados são apresentados ou introduzidos à rede. A camada de saída fornece as respostas aos dados que são apresentados à rede, ou seja, os resultados desejados. Usualmente existem uma ou mais camadas "ocultas" comprimidas entre as camadas de saída e de entrada.

Um neurônio, para atingir um certo grau de atividade ou estado de ativação, deve combinar todos os sinais recebidos num nível de ativação. Esta combinação de estímulos é uma simples soma ponderada, como representada na Equação 7.1. A ativação propriamente dita é resultado da aplicação da função de ativação ao nível de ativação do neurônio " $F(a_i)$ " [177]. O grau de ativação de um neurônio pode estar restrito a um conjunto discreto de valores ou variar continuamente, dependendo da função de ativação utilizada. No caso discreto, são usuais valores binários de ativação "0" e "1". No caso contínuo, normalmente estes valores ficam no intervalo  $[-1 +1]$ .

As funções de ativação " $F(a_i)$ " empregadas com mais regularidade na conexão entre os elementos de entrada e saída são resumidos na tabela 7.1. Tais funções determinam a atividade de um neurônio. Segundo DOS SANTOS [179], embora a " $F(a_i)$ " também seja importante, na prática, a operação do neurônio é geralmente pouco afetada pela natureza exata da função, desde que alguns requisitos básicos sejam satisfeitos. Em contrapartida, a velocidade de treinamento de uma rede pode ser muito alterada pela função utilizada.

Usando funções de ativação lineares (degrau ou linear) para conectar os elementos de entrada e saída, obtém-se um modelo linear. Se forem usadas funções de ativação não-lineares (sigmóides) nesta conexão, tem-se uma rede neural artificial típica, freqüentemente usada nos sistemas inteligentes de monitoramento de processos de fabricação [76]. As funções de ativação não-lineares são as mais usadas para permitir a aprendizagem de estruturas em geral no domínio de  $\Re$ , já que não há limites teóricos sobre o valor da entrada ponderada [179].

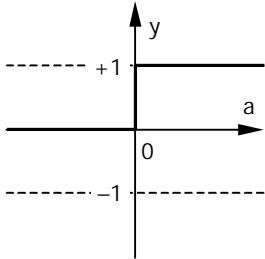
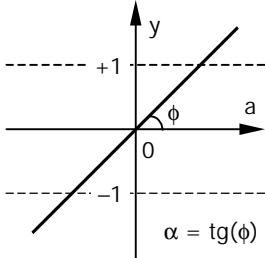
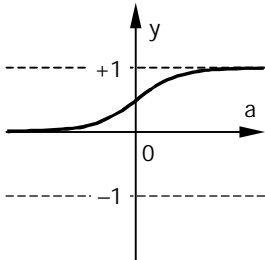
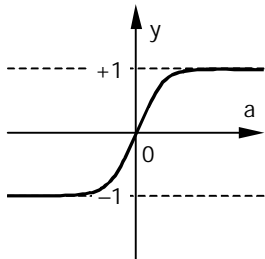
A função de ativação sigmóide é a mais utilizada na maioria dos modelos de redes neurais existentes. Ela é definida como uma função monotonicamente crescente<sup>33</sup>, que exhibe

---

<sup>33</sup> Seja uma função  $f(x)$ , onde  $m$  e  $n$  são dois valores possíveis de  $x$ . A função  $f(x)$  será **monotonicamente crescente** se quando  $m \leq n \Rightarrow f(m) \leq f(n)$ . Já  $f(x)$  será **estritamente crescente** se quando  $m < n \Rightarrow f(m) < f(n)$ .

suavidade e propriedades assintóticas<sup>34</sup>, além de ser contínua e diferenciável em todo o seu domínio, características que conferem grande capacidade de aprendizagem à rede [179].

**Tabela 7.1** – Funções de ativação mais empregadas [117; 119; 180; 181]

Denominação	Equação	Representação Gráfica	
Degrau "hardlim"	$y = \begin{cases} 0 & \text{se } a \leq 0 \\ 1 & \text{se } a > 0 \end{cases}$		(7.2)
Linear "purelin"	$y = \alpha(a)$		(7.3)
Logística "logsig"	$y = \text{sig}(a) = \frac{1}{1 + e^{-a}}$		(7.4)
Tangente Hiperbólica "tansig"	$y = \tanh(a) = \frac{1 - e^{-2a}}{1 + e^{-2a}}$ ou $y = 2 \text{sig}(2a) - 1$		(7.5)


<sup>34</sup> **Assintota** é a linha reta que, prolongada indefinidamente, se aproxima constantemente de uma curva rigorosamente arbitrária sem, entretanto, tocá-la. Por exemplo, as assintotas da função logística (equação 7.4) são dadas pelas constantes  $f(x) = 0$  e  $f(x) = 1$ .



Um exemplo de função sigmóide que talvez seja a mais comumente aplicada é a função logística, equação (7.4), que usa uma variação contínua desde "0" até "1". Algumas vezes torna-se desejável ter uma faixa de ativação variando de "-1" até "1". Em 1986, FRANK H. ECKMAN e WALTER J. FREEMAN<sup>35</sup> mostraram que se uma " $F(a_i)$ " assumir valores negativos, pode-se ter consideráveis vantagens analíticas ao processo de treinamento. A função tangente hiperbólica, equação (7.5), é uma função sigmóide que apresenta tais características.

### 7.3 Topologia de Redes Neurais Artificiais

De acordo com a topologia, uma RNA pode ser classificada como diretas (sem realimentação) ou recorrente (com realimentação). A figura 7.3 mostra estes tipos de rede.




**Figura 7.3** – Topologia para RNA: (a) sem realimentação e camadas isoladas; (b) sem realimentação com conexões diretas entre as camadas de entrada e saída; (c) com realimentação [128]

Na RNA direta, um neurônio envia sua saída apenas para os neurônios dos quais ele não recebe nenhuma entrada direta ou indiretamente (via outras unidades). Em outras palavras, não existem ciclos de realimentação, pois os sinais propagam-se em apenas uma direção: das unidades de entrada para as unidades de saída. Esta topologia implementa um mapeamento estático entradas → saídas. Em certos casos, são necessárias camadas escondidas (ocultas ou internas), para que a rede possa implementar o mapeamento entrada →

<sup>35</sup> ECKMAN, F. H.; FREEMAN, W. J. (1986). The sigmoid nonlinearity in neural computation: an experimental approach. *Neural Networks for Computing, Proceedings of the AIP Conference*, v.151, p.135-9 *apud* DOS SANTOS [179].

saída desejado. Na rede tipo *feedback* os ciclos existem, isto é, os sinais podem se propagar em direções opostas. Em geral, uma RNA com esta topologia forma um sistema dinâmico não-linear. No caso, a estabilidade da rede torna-se um tópico de grande importância [128].

A rede neural direta é geralmente dividida em três partes: a camada de entrada ( $C_E$ ), a camada oculta ( $C_O$ ) e a camada de saída ( $C_S$ ). A camada de entrada " $C_E$ " apresenta " $n$ " elementos de processamento (neurônios), um para cada " $n$ " dimensões do padrão de entrada. Na camada de saída " $C_S$ ", cada nó representa uma classe padrão de conclusão. Se as camadas " $C_E$ " e " $C_S$ " forem diretamente conectadas, a RNA torna-se uma "rede" com função de transferência muito simples, como o mapeamento direto da entrada para a saída. Assim, a camada oculta " $C_O$ " desempenha um papel importante na concepção de uma RNA, pois possibilita o desenvolvimento interno de sua própria representação do mapeamento [76]. A figura 7.4 ilustra uma RNA direta.



**Figura 7.4** – Exemplo de rede neural artificial direta [118; 119; 125; 145; 180]

Para caracterizar uma RNA direta, é necessário pelo menos uma camada de unidades escondidas (camada oculta) com função de ativação não-linear, já que uma RNA que dispõe de unidades lineares ocultas é equivalente a uma RNA sem camada escondida. As unidades de saída podem ter funções de ativação linear ou não-linear.

Os efeitos da interligação de uma RNA são representados na figura 7.5.

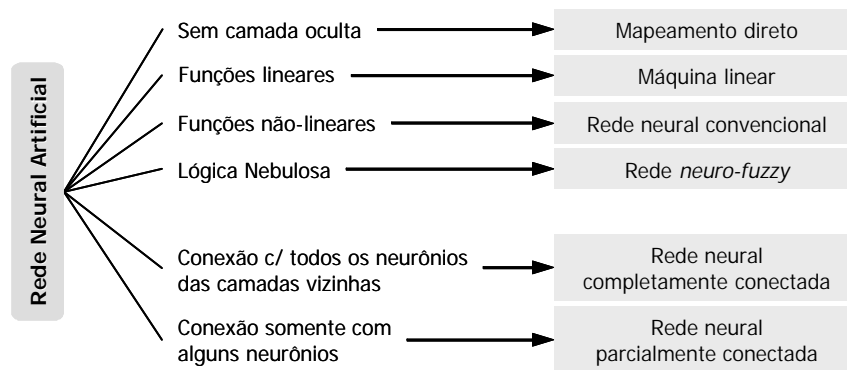


Figura 7.5 – Efeitos da camada oculta numa rede neural artificial [76]

O uso das unidades escondidas torna possível a recodificação dos padrões de entrada. Cada camada oculta ( $C_0$ ) executa a recodificação do seu sinal de entrada. É possível demonstrar, pelo menos teoricamente, que um particular projeto de rede com apenas uma " $C_0$ " é capaz de solucionar a maioria dos problemas práticos (pra não dizer todos) que se apresentam. Entretanto, nada se pode prever a respeito da necessidade de treinamento e exigência computacional que podem tornar a solução impraticável [179]. Quando se tem apenas uma " $C_0$ " com um número de unidades não suficiente para que seja possível a recodificação dos vetores de entrada, uma possível solução é adicionar uma segunda " $C_0$ ". Assim, deve-se decidir entre: (a) usar apenas uma camada oculta com muitas unidades; ou (b) usar duas ou mais camadas ocultas com poucas unidades em cada camada. Normalmente, não mais de duas camadas ocultas são usadas, por duas razões [128]:

- ☑ Provavelmente o poder de representação de uma MLP com até duas camadas ocultas será suficiente para resolver o problema.
- ☑ As simulações têm mostrado que, para a maioria dos algoritmos de treinamento disponíveis atualmente, o tempo de treinamento da rede aumenta com o número de camadas ocultas.

Na literatura, algumas estruturas têm sido mencionadas para aplicação em TCM, destacando: *perceptron* de múltiplas camadas (MLP – do inglês *multilayer perceptron*), redes recorrentes (RNN – do inglês *recurrent neural network*), teoria de ressonância adaptativa (ART – do inglês *adaptive resonance theory*) e redes de Kohonen (KFM – do inglês *Kohonen feature map*).

Dentre elas, a MLP é a mais utilizada, principalmente na classificação de desgastes. A figura 7.6 mostra o percentual de aplicações.




Figura 7.6 – Percentual de aplicações das estruturas das RNA's em TCM (adaptado de [12])

## 7.4 Treinamento em Redes Neurais Artificiais

Na fase de treinamento de uma rede neural artificial, uma regra é usada para alterar os elementos da matriz de pesos “W” (e outros parâmetros modificáveis que a rede possa ter) usando a informação do meio externo, disponibilizada pelo supervisor do treinamento. Nesse contexto, os termos **treinamento**, **aprendizado** e **adaptação** são sinônimos e são interpretados como alterações nos parâmetros modificáveis da RNA [128; 180]. Tal situação é ilustrada pela figura 7.7. Os pesos são ajustados, baseando-se na comparação entre a saída da rede e o valor desejado (alvo), até que a saída o alcance [181].

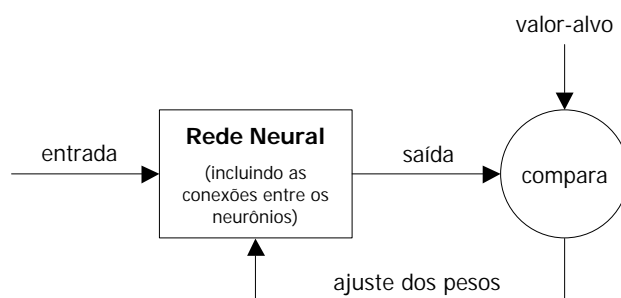


Figura 7.7 – Treinamento supervisionado de redes neurais artificiais [181]

Os diferentes métodos de treinamento podem ser classificados de acordo com a participação do supervisor no processo de aprendizado [128]:

- ☑ **Supervisão muito forte:** o supervisor fornece os valores dos pesos de forma direta para a rede neural artificial.

- ☑ **Supervisão forte:** o supervisor fornece um conjunto de treinamento para a RNA, ou seja, um conjunto de entradas e suas respectivas saídas. Para cada entrada, a saída produzida pela RNA é comparada com a saída fornecida pelo supervisor. Com o intuito de diminuir a diferença entre a saída produzida e a desejada, os pesos são alterados.
- ☑ **Supervisão fraca:** o supervisor atua como um “crítico”, fornecendo uma avaliação grosseira da saída da RNA (certo ou errado, erro grande ou pequeno, sucesso ou fracasso etc.) ao invés de fornecer a saída desejada.
- ☑ **Supervisão muito fraca:** o algoritmo de treinamento da RNA tenta descobrir categorias dos dados de entrada e o supervisor participa apenas fornecendo os “rótulos” para estes agrupamentos.

Na literatura, os termos usuais para denominar treinamento com supervisão forte e treinamento com supervisão muito fraca são, respectivamente, **treinamento supervisionado** e **treinamento não-supervisionado**. A denominação deste último não é totalmente apropriada, visto que há uma pequena (mas efetiva) participação do supervisor no processo.

### 7.4.1 *Treinamento Supervisionado*

O algoritmo de treinamento por *retropropagação*<sup>36</sup> (BP – do inglês *backpropagation*), uma generalização da regra Delta<sup>37</sup>, é, provavelmente, a técnica mais popular de aprendizado supervisionado para aplicações em TCM [119; 128; 180]. O poder do algoritmo BP em conseguir adaptar os pesos de uma MLP vem do fato que tal algoritmo poderá descobrir a recodificação interna necessária para resolver o problema, usando os exemplos do mapeamento entrada-saída desejada. É possível interpretar tal recodificação interna (ou representação interna) como um conjunto de regras. Assim, o BP **extraí** as regras (ou atributos) de um conjunto de exemplos [180].

---

<sup>36</sup> Além do modelo BP de larga aplicação, outros modelos de redes neurais foram propostos ao longo dos anos, cada um deles com suas vantagens e desvantagens [117; 119; 128]: **Perceptrons** (reconhecimento de caracteres), **Adaptive Linear Element** (sistemas de controle), **Counter-propagation** (reconhecimento de padrões e análise estatística), **Hopfield** (recuperação de dados e fragmentos de imagens), **Bidirecional Associative Memories** e **Kohonen** (reconhecimento de padrões).

<sup>37</sup> Para treinar o modelo de neurônio ADALINE (*Adaptive Linear Element*), BERNARD WIDROW e TED HOFF propuseram em 1960 a **regra Delta**, também conhecida como regra de WIDROW-HOFF ou algoritmo LMS (*Least Mean Square*). A regra Delta é uma regra de aprendizado que é baseada no erro médio quadrático MSE (Mean-Square Error) e, portanto, com supervisão forte. Seu princípio básico é alterar, para cada par de treinamento (entrada/saída desejada), os pesos da rede, visando minimizar a diferença entre o valor-alvo e a saída da rede [128].

Apesar das muitas implementações bem sucedidas, as desvantagens do algoritmo BP são bem conhecidas: longo tempo de treinamento; captura do mínimo local<sup>38</sup>; e dificuldades de implementação via *hardware*. Assim, em aplicações em que se desejam altíssimas velocidades computacionais e soluções de baixo custo, este tipo de treinamento não é o mais apropriado [133].

RANGWALA E DORNFELD [15] consideram que um vetor de entrada de grande dimensão (grande número de índices de monitoramento) requer um número apropriadamente grande de padrões de treinamento e, na maioria dos casos, isso torna-se impraticável e/ou caro. Além disso, estes padrões não podem ser interpolados. Por outro lado, o número de características e o número de pesos deve ser o menor possível, ainda que um grande número de padrões de treinamento possa ser usado para treinar a rede. Alguns autores consideram o número mínimo de padrões de treinamento como sendo [15; 76; 182]:

$$N = 2 \cdot (n+1) \quad (7.6)$$


onde "N" é o nº de amostras de treinamento e "n" é o nº de características de entrada.

GHASEMPOOR *et al.* [52] afirmam que não existe uma regra para definir o tamanho do conjunto de treinamento. Contudo, amostras de treinamento muito pequenas resultam em redes que não são capazes de assimilar o aprendizado das relações de entrada-saída, e amostras muito grandes proporcionam o efeito de sobre-treinamento. Em geral, o número apropriado de amostras de treinamento depende dos números de neurônios nas camadas (entrada, saída e oculta) de uma RNA além da complexidade do mapeamento a ser treinado. Como regra prática, o número de amostras de treinamento deve ser 2 vezes o número de pesos de uma rede neural e o número de neurônios na camada oculta deve ser 3 vezes o número de neurônios da camada subsequente [12].

Uma abordagem diferente é citada nos trabalhos de GHASEMPOOR *et al.* [52; 79], ilustrada pela figura 7.8.

---

<sup>38</sup> A taxa de aprendizado " $\eta$ " não deve ser nem muito pequena (treinamento lento) nem muito grande (oscilações). Com " $\eta$ " pequeno e dependendo da inicialização dos pesos (feita de forma aleatória), a RNA pode ficar presa em um mínimo local. Com " $\eta$ " grande, a RNA pode nunca convergir para a melhor solução – o ponto de mínimo global –, pois as oscilações são grandes [128].



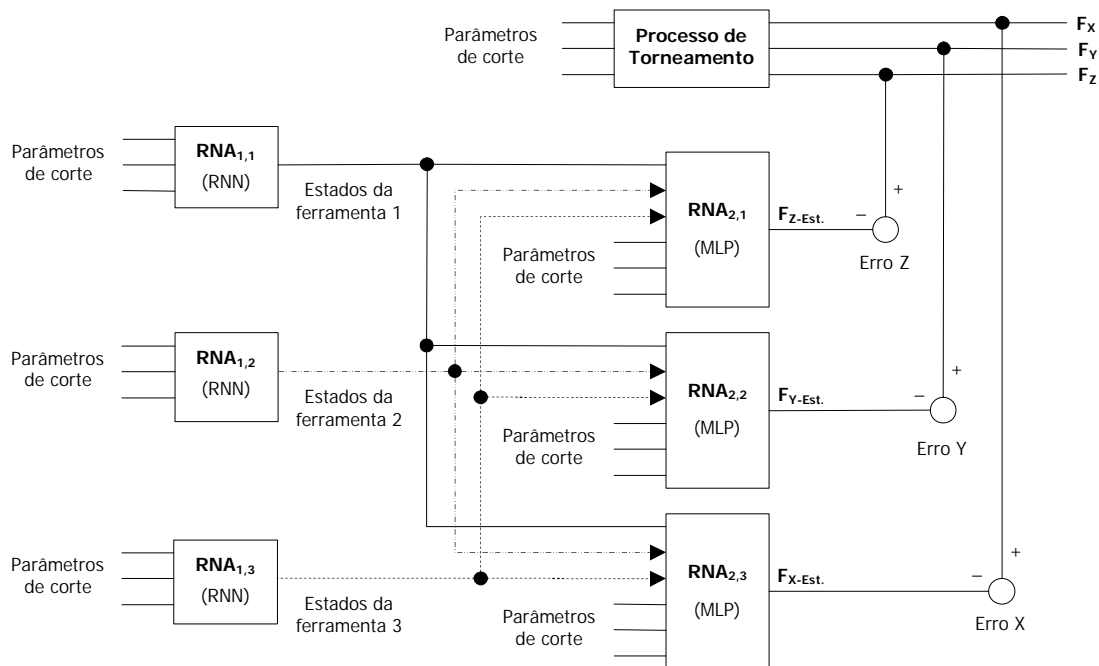


Figura 7.8 – Modelo de uma operação de torneamento [52; 79]

Na figura 7.8, a operação de torneamento foi considerada como sendo um sistema dinâmico não-linear modelado através de uma combinação hierárquica de redes neurais seriais estáticas (MLP) e dinâmicas (RNN). As saídas do sistema (observáveis) são as componentes da força de usinagem e as entradas são as diferentes condições de corte. Os estados da ferramenta (desgastes de flanco, quina, cratera e entalhe) são parâmetros internos do sistema (não-observáveis). As RNA's atuam como um observador linear para estimar os estados (desgastes) da ferramenta. Infelizmente, o sistema não separa os efeitos causados pelo aumento dos desgastes induzidos pela variabilidade das condições de corte [52; 79].

Uma vez que os dados de treinamento da rede neural supervisionada tenham sido selecionados, os problemas subseqüentes, na ordem em que devam ser resolvidos, podem ser classificados em três áreas principais: **representação**, **aprendizado** e **generalização**.

### (a) Representação

O problema de **representação** está em como projetar a estrutura da RNA, de tal forma que exista pelo menos uma solução (conjunto de pesos para a rede) que possa aprender o conjunto de dados de treinamento. Tal conjunto de dados deve conter a relação que a rede deve adquirir.

O tamanho da rede neural define o número de camadas ocultas (intermediárias, escondidas etc.) e o número de neurônios (unidades computacionais) em cada uma dessas camadas. Isto define o compromisso entre aprendizado (convergência) e generalização. Por exemplo, se a rede for pequena, não será capaz de armazenar todos os padrões necessários. Se a rede for muito grande (as matrizes que contém os pesos sinápticos e os limiares são de grande dimensão), não responderá corretamente aos padrões nunca vistos.

## (b) Aprendizado

Aprendizagem ou convergência é a capacidade da RNA de aprender todos os padrões do conjunto de treinamento. O problema de aprendizado refere-se a como treinar a rede. Os algoritmos de retropropagação podem ser classificados em duas classes principais, conforme a **taxa de aprendizado** " $\eta$ " [128]:

- ☑ Algoritmos que tentam convergir para a solução de mínimo global: apresentam taxa de aprendizado pequena e, por isso, a velocidade de convergência é baixa. Dependendo da inicialização dos pesos (em geral, pequenos números aleatórios centrados em torno do zero), a RNA pode ficar presa em pontos de mínimo local e assim não conseguir aprender com a precisão especificada (erro mínimo). A solução é utilizar uma **taxa de aprendizado adaptativa**, que permite a variação considerável dos pesos no início do treinamento e realiza no fim uma espécie de "ajuste fino" nas matrizes de peso.
- ☑ Algoritmos que tentam convergir rapidamente: com uma grande taxa de aprendizado, a RNA pode nunca conseguir chegar ao mínimo global, pois as oscilações são grandes. Duas soluções possíveis: (1) incluir um **termo de momento** na atualização dos pesos sinápticos para acelerar o aprendizado e filtrar as oscilações; (2) alterar o valor a taxa de aprendizado.

Existem diferentes variações do algoritmo de treinamento por retropropagação; algumas destas serão sumariadas mais adiante. A implementação mais simples de aprendizado (ou convergência) atualiza os pesos e os valores de polarização da RNA para que a função de desempenho (negativo do gradiente) diminua mais rapidamente. Equacionando:

$$x_{k+1} = x_k - \eta \cdot \nabla_k \cdot W \quad (7.7)$$

onde " $x_k$ " é o vetor atual de pesos e limiares, " $\nabla_k$ " é o gradiente atual, " $\eta$ " é a taxa de aprendizado e " $W$ " é a matriz de pesos.



Existem dois modos básicos de aplicação do algoritmo BP no qual o algoritmo gradiente-decrescente pode ser implementado [128, 181]: **em lotes** [train] e **incremental** [adapt]. O modo [train] necessita de menos atualizações de pesos e, portanto, tende a ser mais rápido, já que todas as entradas são aplicadas na rede antes que os pesos sejam atualizados. No modo [adapt], o gradiente é computado e os pesos são atualizados após cada entrada aplicada na RNA. Assim, o algoritmo tem menos chance de ficar preso em um mínimo local devido à apresentação aleatória dos padrões (natureza estocástica de busca no espaço de pesos).

Os algoritmos de aprendizado rápido são subdivididos em duas categorias [181]:

- ☑ **Técnicas heurísticas**<sup>39</sup>, desenvolvidas a partir de uma análise do desempenho do algoritmo gradiente-decrescente padrão. As funções a serem analisadas no trabalho são:
  - [train~~gdx~~]. Se a taxa de aprendizagem “ $\eta$ ” é muito alta, o algoritmo de aprendizagem pode oscilar e tornar-se instável. Se a taxa é muito baixa, o algoritmo converge muito lentamente. Assim, não se recomenda que se determine um valor ótimo para “ $\eta$ ” antes do treinamento, já que ele muda durante o processo. O desempenho do algoritmo gradiente descendente pode ser então melhorada se a taxa de aprendizado puder ser modificada durante o treinamento. Assim, a função de treinamento [train~~gdx~~] utiliza-se de uma taxa de aprendizado adaptativa com um termo de momento na atualização dos pesos sinápticos.
  - [train~~rp~~]. As funções de ativação tipo sigmóide são caracterizadas pelo fato de que seu declive precisa aproximar-se de zero quando a entrada torna-se grande. Isto gera um problema quando se utiliza gradiente descendente para treinar uma rede multicamadas com funções sigmóides, já que o gradiente pode ter uma magnitude muitíssimo baixa, causando assim mudanças insignificantes nos pesos e nos limiares, mesmo que estejam muitíssimos distantes de seus valores ótimos. O propósito da função de treinamento [train~~rp~~] é eliminar estes efeitos prejudiciais às magnitudes das derivadas parciais a partir da retropropagação flexível.
- ☑ **Técnicas de otimização numérica**, divididas em três tipos:
  - [train~~cgf~~]. O algoritmo básico de treinamento BP ajusta os pesos na direção descendente (negativo do gradiente). Embora a função decresça mais rapidamente

---

<sup>39</sup> A técnica **heurística** é uma metodologia ou um algoritmo usado para resolver problemas por métodos que, embora não rigorosos, geralmente refletem o conhecimento humano e permitem obter uma solução satisfatória.

pelo negativo do gradiente, isto não necessariamente garante uma rápida convergência. Nos algoritmos de gradiente conjugado, observa-se uma convergência mais rápida nas direções conjugadas que nas direções descendentes. Na maioria dos algoritmos conjugados, a extensão das atualizações dos pesos é ajustada em cada iteração (ciclo de treinamento ou *epoch*), levando a um aumento do número de cálculos computacionais. A vantagem disso é que a função de treinamento [`traincgf`] (Fletcher-Reeves) converge em menos iterações que a função [`trainrp`].

- o [`trainbfg`]. O método BFGS (Broyden, Fletcher, Goldfarb e Shanno) quasi-Newton é uma variação alternativa do algoritmo de gradiente conjugado para rápida otimização. O passo básico do método é representado pela equação:

$$x_{k+1} = x_k - \eta \cdot (A_k)^{-1} \quad (7.8)$$

onde " $A_k$ " é a matriz de Hessian (2ª ordem) dos coeficientes de performance dos valores atuais dos pesos e limiares. Apresenta mais cálculos computacionais em cada iteração que a função [`traincgf`], mas converge em menos iterações. Por isso, em redes muito grandes, é melhor usar a função [`trainrp`] ou a [`traincgf`]. Já em redes pequenas, a função [`trainbfg`] pode ser uma solução eficiente.

- o [`trainlm`]. O algoritmo de memória reduzida Levenberg-Marquardt foi desenvolvido para abordar a velocidade de treinamento de 2ª ordem sem precisar calcular a matriz de Hessian. A função [`trainlm`] aparece como o método de treinamento mais rápido para redes FFNN de tamanho médio (algumas centenas de pesos). A sua principal desvantagem é precisar armazenar algumas matrizes que podem ser bastante grandes para certos problemas. Ainda que se use a redução de memória, o algoritmo de Levenberg-Marquardt sempre calculará a matriz aproximada de Hessian. Se a rede for muito grande, então haverá perda de memória. Neste caso, dever-se-á usar a função [`trainrp`] ou a [`traincgf`].

### (c) Generalização

Uma vez que o treinamento tenha terminado, o problema de **generalização** consiste em determinar como a RNA irá responder a dados que não estavam presentes no conjunto de treinamento. Uma medida de generalização da rede é obtida verificando-se o desempenho da rede, usando um conjunto de dados de teste (dados não utilizados durante o treinamento). Um excessivo número de pesos pode resultar em sobre-treinamento [12]. Assim, a generalização de uma rede é considerada "boa" quando a aplicação na entrada da rede de

um conjunto de dados de teste resulta em valores de saída corretos [128]. A generalização é influenciada por 3 fatores: (a) tamanho e eficiência do conjunto de treinamento; (b) arquitetura da rede (número de neurônios); (c) complexidade do problema (não se tem controle).

Duas formas de avaliar a generalização: (a) manter a arquitetura da RNA fixa e encontrar o tamanho apropriado do conjunto de treinamento; (b) manter o tamanho do conjunto de treinamento fixo e determinar a melhor arquitetura da RNA. A situação ideal, portanto, é determinar o menor número de neurônios na camada oculta que possa produzir o mapeamento entrada-saída desejado da forma mais suave possível.

### 7.4.2 Treinamento Não-supervisionado

O treinamento não-supervisionado justifica-se pelo fato da obtenção das informações confiáveis sobre o desgaste da ferramenta, necessárias para se treinar uma RNA, envolver custos elevados. Também porque as operações de usinagem precisam ser interrompidas visando adquirir dados sobre o estado da ferramenta. Além disso, quando existe a necessidade de se manipular uma infinidade de combinações de ferramentas, materiais e condições de corte num sistema de monitoramento, um aprendizado supervisionado como o de retropropagação passa a ser indesejável [28; 83; 183; 184].

Com o desenvolvimento da teoria de ressonância adaptativa (ART – *Adaptive Resonance Theory*), proposta inicialmente por STEPHEN GROSSBERG em 1976, as redes neurais aplicadas no reconhecimento e classificação de padrões (voz, radar, sonar) passaram a ser não-supervisionadas. Os modelos ART (ART-1 usa entradas binárias; ART-2 admite padrões de entrada analógicos) são mais adaptáveis ao aprendizado e à resposta *on-line* para sinais de entrada não-estacionários, com ilimitado número de entradas, até que toda sua capacidade de memória seja utilizada. Comparada com outras redes, a ART-2 apresenta as seguintes habilidades [65]:

- ☑ Aprendizagem em tempo real, sem a necessidade de muitas amostras de treinamento.
- ☑ Fácil adaptação às mudanças do meio.
- ☑ Estabilidade: preserva os conhecimentos adquiridos previamente.
- ☑ Auto-organização em resposta a seqüências arbitrárias de entrada.

Pesquisas recentes usaram modelos ART-2: (a) na fusão de sinais de força e EA; e (b) na tomada de decisão sobre o estado do desgaste de flanco [29; 65; 83; 108; 127].

Em 1981, TUEVO KOHONEN, da Universidade de Helsinque, demonstrou que modelos de redes neurais podiam representar um espaço de entrada multidimensional em um espaço

de saída (usualmente) uni ou bidimensional usando treinamento não-supervisionado [83; 185]. Ele denominou o processo de “mapas auto-organizáveis” (SOM – do inglês *self-organizing map*). A ideia do SOM ou KFM (*Kohonen Feature Map*) é obter um mapeamento entrada/saída, em que a topologia do espaço de entrada seja preservada no espaço de saída. Assim, entradas que são próximas no espaço de entrada são mapeadas para saídas próximas no espaço de saída, ou seja, ativarão unidades de saída que estão fisicamente próximas. Uma redução gradual (da vizinhança) objetiva permitir a formação de tal mapeamento, pois unidades de saída vizinhas são atualizadas de forma semelhante. Dessa forma, unidades de saída vizinhas, após o treinamento, respondem às entradas “vizinhas” (entradas similares no espaço de entrada) [128]. A figura 7.9 ilustra tal mapeamento.




Figura 7.9 – Mapas auto-organizáveis de Kohonen [185]

Para que a rede KFM seja prática e confiável em TCM, é preciso que a RNA [83]:

- ☑ Utilize amostras de treinamento sem informações totalmente corretas sobre os desgastes da ferramenta, permitindo-se com isso interpretar os resultados auto-organizados com um número mínimo de amostras “supervisionadas”.
- ☑ Selecione as características de entrada automaticamente e de maneira apropriada a partir de dados sensórios ruidosos, de forma que se possam evitar limitações severas devido ao uso de características selecionadas *off-line*.

Apesar de tudo que foi apresentado, Sick [12] afirma que é difícil de acreditar que redes com treinamento não-supervisionado possam ser aplicadas com sucesso em sistemas TCM projetados para utilização em chão-de-fábrica.

### 7.4.3 Sobretraining e Subtreinamento

Há casos em que uma RNA que contém um número excessivo de neurônios na camada oculta, um demasiado número de pesos, ou que possui ruídos no conjunto de dados (pares) de treinamento, apresenta um erro muito baixo na etapa de treinamento e um erro muito alto quando novos dados de entrada são apresentados. Este fenômeno é conhecido por **sobretraining** (do inglês *overfitting*). Isto ocorre porque a RNA memorizou os exemplos de treinamento, mas não aprendeu a se “generalizar” para novas situações [181]. O problema de generalização consiste em determinar como a rede irá responder a dados que não estavam presentes no conjunto de treinamento. Se a RNA não tem boa capacidade de generalização, a curva de ajuste passa exatamente por todos os pontos usados durante o treinamento, sem adquirir a relação verdadeira entrada-saída (E/S) que gerou os pontos. Nesse caso, o algoritmo de treinamento está tentando “modelar” também o ruído, o que não é desejável. A consequência disto é um desempenho inadequado quando o teste é executado. Portanto, a situação ideal é determinar a melhor topologia que possa produzir o mapeamento E/S mais suave possível [128].

A figura 7.10 mostra a resposta de uma RNA com configuração 1-20-1 treinada para se aproximar de uma função seno. A função seno (valor-alvo) é representada pela linha pontilhada, os valores medidos (entradas) pelos símbolos “O” e a resposta da rede (saída) pela linha contínua (cinza). Pode-se observar que houve sobretraining e a rede não apresentou boa capacidade de generalização, pois se ajustou exatamente aos pontos “O”.




Figura 7.10 – Representação do sobretraining [181]

Por outro lado, situações em que a rede neural apresenta um número insuficiente de neurônios na camada oculta resultam no fenômeno chamado **subtreinamento** (do inglês *underfitting*). Neste caso, os pesos e os valores de polarização da rede não conseguem originar saídas com valores razoavelmente próximos aos valores do conjunto de treinamento, proporcionando soluções com erros analogamente muito elevados [179].

## 7.5 Estimativa, Classificação ou Identificação (Tomada de Decisão)

Usualmente, apenas um parâmetro de desgaste é classificado ou estimado por redes neurais. Somente algumas poucas publicações desenvolveram RNA's com múltiplas saídas, como nos trabalhos de RAHMAN *et al.* [69] e ZHOU *et al.* [23], por exemplo, em que a rede proporciona a classificação de desgastes, vibração auto-excitada e quebra do cavaco. Tal abordagem é significativa caso os parâmetros de saída da RNA correlacionem-se entre si.

Os trabalhos de pesquisa mostram diferentes modelos para a estimativa de desgastes ou classificação dos níveis de desgastes da ferramenta de corte em torneamento na chamada **etapa de decisão** de uma RNA. Esta etapa pode apresentar:

- ☑ Uma saída (resposta) de um modelo de desgaste [83].
- ☑ Diferentes saídas de um modelo de desgaste [68; 69; 183].
- ☑ Diferentes estimativas ou classificações de um tipo de desgaste através de diferentes modelos de desgastes [66; 106].
- ☑ Estimativa ou classificação de diferentes tipos de desgaste [186; 187].

Com o intuito de suavizar a saída do sistema TCM inteligente, alguns trabalhos propuseram calcular a média aritmética de diferentes números de saídas para uma RNA: 3 foram usadas por LEEM E DORNFELD [183], 8 por HONG *et al.* [68]; e 10 por RAHMAN *et al.* [69].

CHRYSSOLOURIS *et al.* [66] descrevem, através de modelos analíticos, a complexa dependência dos sinais mensurados em relação: aos parâmetros do processo (forças de avanço e de corte, emissão acústica e temperatura); às condições de corte; e aos parâmetros de desgaste. Estes modelos – definidos no item 5.3 como índices de monitoramento – quantificam indiretamente os desgastes, os quais são usados como entradas de uma rede MLP. A rede gera uma estimativa final na etapa de decisão.

KAMARTHY E PITTNER [106] usam uma RNA para cada sinal sensorio e fundem tais informações com uma fórmula simplificada na etapa de decisão.

SILVA *et al.* [83] verificaram a saída do modelo visando remover classificações ilógicas da RNA. Logo, um modelo analítico simples baseado na equação da vida da ferramenta de Taylor foi usado. As duas abordagens são complementares, pois a RNA estima o valor de desgaste e a equação de Taylor estabelece os limites de validação baseados em conhecimentos empíricos, ou seja, os valores estimados de VB são descartados quando:

$$\begin{aligned} VB_{RNA} &> VB_{Taylor} + 0,15 \\ &\text{ou} \\ VB_{RNA} &< VB_{Taylor} - 0,15 \end{aligned} \quad (7.7)$$


As estimativas do valor da largura de desgaste de flanco (VB) e do crescimento de "VB" (ambos no gume principal) foram usados por OBIKAWA *et al.* [188] para determinar a estimativa final de "VB". Este valor final foi determinado através do cálculo da média aritmética entre a estimativa atual (RNA 1) e a soma da estimativa atual da taxa de crescimento de "VB" (RNA 2) com a estimativa preliminar (RNA 1), como mostra a equação (7.8). Com base neste valor, os autores buscavam ajustar as condições de corte ( $f$  e  $v_c$ ).

$$\overline{(VB)}_t = \frac{1}{2} \left\{ (VB)_t + \left[ (VB)_t \Delta t + (VB)_{t-\Delta t} \right] \right\} \quad (7.8)$$

LI *et al.* [1] usam a rede para classificar desgastes severos, quebra e vibração auto-excitada para concluir sobre a falha da ferramenta.

Após a apresentação das considerações gerais sobre: monitoramento do estado da ferramenta de corte (Capítulo 5), reconhecimento da falha via sinais indiretos (Capítulo 6) e tomada de decisão via redes neurais artificiais (Capítulo 7), far-se-á no Capítulo 8 uma apresentação minuciosa sobre a **Formação da Base de Conhecimento**, de modo a poder mostrar as correlações entre as variáveis dependentes de saída (força de usinagem, vibrações, rugosidade, falhas na ferramenta de corte).

## 8 - FORMAÇÃO DA BASE DE CONHECIMENTO



*“O sistema ideal de monitoramento do estado da ferramenta precisa abranger toda a natureza complexa e diversa da operação de corte”.*

D. E. DIMLA, P. M. LISTER E N. J. LEIGHTON

As regras de inferência especificam a relação entre as variáveis de entrada e saída, representando o conhecimento de especialistas, os resultados de pesquisas, ou ainda, os sistemas de avaliação. Para a elaboração das regras, são necessários inúmeros questionamentos, pesquisas, observações etc. do fenômeno, no intuito de extrair o maior número de informações referentes à relação. Este processo chama-se **aquisição do conhecimento**.

Pesquisar sobre as regras significa achar resposta para perguntas do tipo:

- O que aconteceu com a largura da marca de desgaste de flanco “VB” da ferramenta quando a força passiva “F<sub>p</sub>” atingiu um valor 20% superior ao valor inicial (gume novo)?
- Como reconhecer na ferramenta de corte a mudança do estágio progressivo para o catastrófico a partir da análise da amplitude da tensão elétrica “EA<sub>RMS</sub>” de saída do transdutor de emissão acústica?
- O que representa, em relação ao estado atual da ferramenta, um pico de curtose (de altíssima amplitude) da distribuição-β dos dados extraídos do sinal de vibração?

Assim, regras do tipo [**se... então...**] são aplicadas, com o objetivo único de verificar o comportamento dos sinais de força, vibração e emissão acústica no reconhecimento de padrões de falha na ferramenta de corte durante o processo de torneamento.

Como a intenção do trabalho é associar os sinais com o estado da ferramenta, as **variáveis independentes** de entrada (material da peça e da ferramenta; geometria da peça e da ferramenta; parâmetros de corte; meio lubri-refrigerante; e máquina-ferramenta) foram mantidas constantes (desprezando as considerações preliminares, item 8.2.2), de modo que as correlações entre as **variáveis dependentes** de saída (força de usinagem; vibrações; rugosidade; falhas na ferramenta de corte) pudessem ser avaliadas.



Para tanto, as características do corpo de prova (geometria, microestrutura, dureza e composição química) foram obtidas. Em seguida, pesquisou-se sobre a funcionalidade do inserto de metal-duro (geometria, recobrimento, suporte e faixa de aplicação). Com o programa inserido na máquina (ciclo de desbaste), foi possível garantir as mesmas condições de corte em todos os passes realizados durante o torneamento a seco. No início de cada passe, a aquisição dos sinais foi efetuada (monitoramento indireto). No final de cada passe, o inserto foi removido da máquina para ser fotografado através de uma câmera CCD (monitoramento direto). Assim, foi possível correlacionar as falhas detectadas no flanco da ferramenta com os sinais monitorados e com isso determinar as **regras de inferência**.

## 8.1 Arquitetura do Sistema Experimental

A figura 8.1 esquematiza a arquitetura do sistema experimental completo.

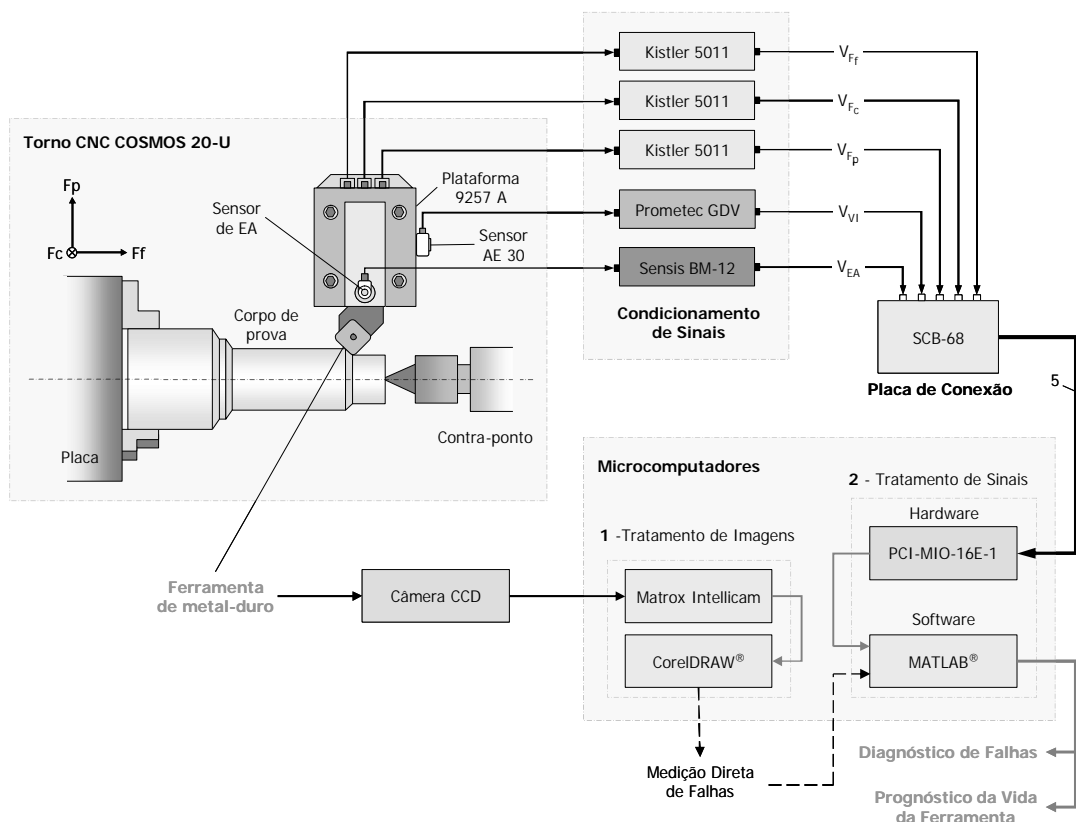



Figura 8.1 – Arquitetura do sistema experimental completo

### 8.1.1 Corpo de Prova

A preparação do corpo de prova consistiu de quatro etapas. Primeiramente, a barra laminada (recozida para alívio de tensões) de aço-carbono ABNT 1040 foi cortada em tarugos de aproximadamente 450 mm de comprimento. Após isso, executou-se o furo de centro. Em seguida, os tarugos passaram por operações de desbaste (radial e longitudinal) visando eliminar sujeiras e óxidos superficiais, além da correção do furo de centro. Para uniformizar o diâmetro inicial em cerca de 100 mm, suprimir os defeitos de cilindridade e eliminar uma possível camada encruada, realizou-se um novo passe.

A figura 8.2 ilustra as fotos da microestrutura do aço ABNT 1040 em cortes longitudinal e transversal, obtidas no Laboratório de Materiais (LABMAT – UFSC) através do microscópio OLYMPUS modelo BX60 com uma ampliação de 200 vezes.



**Figura 8.2** – Microestrutura do material: apresenta 52% de perlita (áreas mais escuras, maior dureza) e 48% de ferrita (áreas mais claras); o número do tamanho de grão conforme a Norma ASTM E112<sup>40</sup> está entre 6 e 7 (granulometria fina)


Almejando conhecer a variação da dureza da superfície do tarugo até o núcleo, foram realizados ensaios de dureza na escala Brinell (HB). Para tanto, traçou-se um perfil de

---

<sup>40</sup> Segundo a Norma ASTM E112 **Métodos Padronizados para Estimativa do Tamanho Médio dos Grãos de Metais** (*Standard Methods for Estimating the Average Grain Size for Metals*), para cada um dos diferentes quadros comparativos padronizados, é atribuído um número que varia de 1 a 10. Este número é conhecido por número do tamanho do grão "n". Quanto maior este número, menor o tamanho do grão austenítico [199]. Se "N" representa o número médio de grãos por polegada quadrada a uma ampliação de 100 vezes, então:

$$N = 2^{n-1}$$

identações<sup>41</sup> na direção radial com espaçamento de 5,5 mm entre elas. Para cada valor de raio, tomou-se quatro pontos, espaçados de 90° na superfície. O perfil de dureza pode ser visualizado na figura 8.3. Os valores de dureza encontrados encontram-se na faixa indicada para o aço em questão [190]. Sendo assim, constatou-se que a variação verificada ao longo do raio do corpo de prova não foi significativa para o escopo do presente trabalho.



**Figura 8.3** – Perfil de dureza do material do corpo de prova. Segundo CALLISTER [199], o material apresenta média dureza, tomando como referência aços com percentual de carbono entre 0,25% e 0,50%.

A composição química do material foi verificada via espectrometria de emissão óptica<sup>42</sup>, como mostra a tabela 8.1. Através da comparação entre as percentagens medidas e tabeladas pelo padrão ABNT, pode-se ver que todos os elementos estão dentro das faixas previstas para o aço de construção mecânica ABNT 1040 [190].

**Tabela 8.1** – Composição química do material do corpo de prova

%	Fe	C	Mn	P	S	Outros
<b>Medida</b>	98,267 ± 0,058	0,405 ± 0,003	0,713 ± 0,019	0,013 ± 0,002	0,021 ± 0,005	0,581 ± 0,042
<b>Padrão ABNT</b>	---	0,37 ~ 0,44	0,6 ~ 0,9	0,030 máx.	0,050 máx.	---

<sup>41</sup> Ensaios de dureza e microdureza são importantes ferramentas para previsão e comparação do comportamento mecânico de materiais metálicos. Nos ensaios por penetração, mede-se geralmente a deformação causada na superfície da amostra pela pressão de uma ferramenta, denominada indentador. Os métodos usuais de medida diferem pela forma desta ferramenta e pela carga aplicada [200].

<sup>42</sup> A espectrometria de emissão óptica permite a determinação da natureza e concentração dos elementos químicos presentes no material através da faixa e intensidade da radiação luminosa emitida pela amostra, quando submetida a uma excitação [200].

### 8.1.2 Máquina-ferramenta

A máquina-ferramenta utilizada foi o torno Romi® modelo COSMOS 20-U com comando numérico computadorizado Romi® modelo MACH-7. A figura 8.5 mostra a foto do torno no Laboratório de Mecânica de Precisão (LMP-UFSC).



**Figura 8.4** - Torno CNC Romi® COSMOS 20-U

Vale salientar que a máquina apresenta modificações (relativas ao modelo original) referentes ao carro porta-ferramentas: o cabeçote rotativo para múltiplas ferramentas foi substituído por um cabeçote fixo para uma única ferramenta.

### 8.1.3 Ferramenta de Corte

A pastilha negativa SANDVIK (T-MAX P) tipo **SNMG 120408-PM** é usada no torneamento geral externo de aço-carbono ( $C = 0,25 \sim 0,55\%$ ). Apresenta geometria quadrada (ângulo de quina  $\epsilon_r = 90^\circ$ ), dupla face com quebra-cavacos multifunção, ângulo de folga " $\alpha$ " =  $0^\circ$ , comprimento " $l$ " = 12 mm, espessura " $s$ " = 4 mm, raio de quina " $r_e$ " = 0,8 mm.

A cobertura **GC4025** da pastilha pertence a uma classe de uso geral (P10-P35), aplicada em velocidades de corte de médias a altas até com taxas de avanço relativamente altas. É formada por uma camada espessa de óxido de alumínio ( $Al_2O_3$ ) no topo de uma camada de tamanho médio de  $Ti[C,N]$ . Uma fina camada externa de nitreto de titânio  $TiN$  (cor

amarelada) facilita a identificação das falhas (avarias e desgastes). A espessura total do revestimento é de aproximadamente 10  $\mu\text{m}$  [191].

O suporte ISCAR tipo **PSBNL 2525M-12** foi usado na usinagem externa. Apresenta fixação por alavanca, ângulo de posição da ferramenta " $\chi_r$ " = 75°, ângulo de folga " $\alpha$ " = 0°, corte à esquerda, altura da haste " $h$ " = 25 mm, largura " $b$ " = 25 mm, comprimento " $l_1$ " = 150 mm, ângulo de saída " $\gamma$ " = -6°, ângulo de inclinação " $\lambda$ " = -6° [192].

A figura 8.4 ilustra a aplicabilidade da ferramenta usada nos experimentos segundo dados do fabricante.

$v_c$ [m/min]	$f$ [mm]	$a_p$ [mm]	Operação	Prováveis falhas encontradas
415	0,19	1,0	SEMI-ACABAMENTO	Desgaste de flanco (uniforme), entalhe, cratera (+), deformação plástica. $VB \cong VB_{m\acute{a}x}$ .
⋮	⋮	⋮		
<b>350</b>	<b>0,3</b>	<b>1,5</b>	<b>Usinagem Média</b>	<b>SNMG 120408-PM 4025</b> ( $\chi_r = 75^\circ$ ) $\gamma(-)$ : favorece a craterização, os microlascamentos e a vibração
⋮	⋮	⋮		
290	0,47	5,0	DESBASTE LEVE	Desgaste de flanco (irregular), lascamentos, cratera (-), quebra do gume. $VB < VB_{m\acute{a}x}$

Figura 8.5 – Ferramenta de corte T-Max P Sandvik Coromant [191]

### 8.1.4 Sistema de Medição Direta

A medição direta dos desgastes ocorreu através de uma câmera CCD P/B 1/2 marca PULNIX, modelo TM-7CM auxiliada pelo software MATROX INTELICAM INTERACTIVE. O procedimento consistiu da aquisição e armazenamento de imagens (fotos) da ferramenta extraídas ao longo da vida da ferramenta em intervalos de tempo predefinidos (fig. 8.6).

O tratamento posterior das imagens (ampliadas aproximadamente 50 vezes) para a quantificação dos desgastes foi executado pelo aplicativo CoreIDRAW® (medição diferencial a partir do deslocamento de linhas-guia obtidas da ferramenta nova tomada como padrão).




**Figura 8.6** – Sistema de medição direta via câmera CCD

### 8.1.5 Sistema de Monitoramento Indireto

#### (a) Sensoriamento

O **transdutor** é um dispositivo do sistema de monitoramento que está em contato com o mensurando. Gera um sinal proporcional (mecânico, elétrico ou outro) ao mensurando segundo uma função bem definida – normalmente linear – baseada em uma ou mais grandezas físicas. Em termos gerais, um transdutor transforma uma grandeza física noutra. O primeiro módulo do transdutor, aquele que entra em contato diretamente com o mensurando, é denominado de **sensor**. A rigor, sensor é uma parte do transdutor. Usualmente, aplica-se o termo sensor para denominar o equipamento que caracteriza os “sentidos” do sistema de monitoramento.

Para a captação dos sinais de **força**, o dinamômetro piezelétrico KISTLER® modelo 9257A de três componentes ortogonais da força de usinagem foi usado. As vantagens deste sistema em forma de plataforma são: a separação das três componentes, a altíssima rigidez e a frequência natural elevada. Por outro lado, apresentam-se as desvantagens como o alto custo e a presença de cabos de conexão, que tornam este sistema pouco prático. A figura 8.7 mostra a plataforma em questão.



**Figura 8.7** – Plataforma piezométrica KISTLER® 9257ª

Na coleta de sinais de **vibração**, aplicou-se um transdutor com cristal piezométrico PROMETEC® modelo AE 30 (fig. 8.8), para a detecção de uma ampla faixa de sinais de vibração com frequências entre 0,1 e 80 kHz.



**Figura 8.8** – Sensor de vibração e/ou ultra-som PROMETEC® AE 30

Na aquisição dos sinais de **emissão acústica**, utilizou-se um transdutor com cristal piezométrico SENSIS® com fixação por parafuso (fig. 8.9) para a detecção de uma ampla faixa de sinais com frequências superiores a 1 kHz.



**Figura 8.9** – Sensor de emissão acústica SENSIS®

## (b) Condicionamento dos sinais

Os sinais sensórios são geralmente incompatíveis com a placa de aquisição de sinais. Para que essa incompatibilidade seja superada, o sinal necessita ser condicionado. Por exemplo, é preciso que o sinal de entrada seja amplificado e/ou que apresente o mínimo de ruído possível. Apesar dos sinais de saída também precisarem ser condicionados, será discutido apenas o condicionamento dos sinais de entrada.

Os sinais de **força** obtidos nos canais “ $F_x$ ”, “ $F_y$ ” e “ $F_z$ ” da plataforma correspondem respectivamente às componentes “ $F_f$ ”, “ $F_p$ ” e “ $F_c$ ” geradas no processo de torneamento. Os valores de sensibilidade (T) da plataforma 9257A juntamente com os fatores de escala (S), devem ser devidamente ajustados nos três amplificadores de carga KISTLER® modelo 5011 usados no condicionamento dos sinais (fig. 8.10).



Figura 8.10 – Amplificador de carga KISTLER® 5011

Com os devidos ajustes, foi possível observar, por exemplo, que 1 V gerado na saída do amplificador de carga X correspondia a uma força aplicada “ $F_f$ ” de 200 N. A calibração da plataforma é descrita no Anexo A.1. Apesar da possibilidade da utilização ou não de filtros “FPB” (10 Hz a 30 kHz), foi resolvido não usá-los para caracterizar seguramente os sinais brutos de força.

O condicionamento do sinal de **vibração** foi feito através do pré-amplificador PROMETEC® modelo GDV (figura 8.11). O sinal captado pelo sensor AE 30 foi primeiramente amplificado (ganho ajustado para 10 dB) e posteriormente filtrado, visando amortecer e minimizar interferências externas. Como o sensor foi projetado para trabalhar numa larga faixa de frequências (100 Hz a 80 kHz), resolveu-se limitar esta faixa de operação usando um “FPF” *plug-in* de 5 a 25 kHz.



Figura 8.11 – Pré-amplificador PROMETEC® GDV



O monitor de **emissão acústica** SENSIS® modelo BM-12 usado no condicionamento do sinal de EA é mostrado na figura 8.12.



**Figura 8.12** – Sistema monitor de emissão acústica SENSIS® BM-12

O sinal captado pelo sensor é primeiramente amplificado (ganho regulável) para compensar diferenças na sensibilidade (posição, propagação do sinal, saturação) e obter uma taxa sinal/ruído ótima. O nível de sinal é indicado com uma barra de LED's (do inglês *Light Emission Diode*). Em seguida, o sinal é filtrado por um FPA *plug-in* (50 kHz), visando amortecer e minimizar interferências externas. O sistema possui duas saídas analógicas: sinal tratado "EA<sub>RMS</sub>" e sinal bruto "EA<sub>RAW</sub>". A constante de tempo para o cálculo do valor RMS é definida pela equação:

$$\tau = \frac{25 \text{ ms}}{1 \mu\text{F}} \times C \quad (8.1)$$

onde "C" é o valor da capacitância selecionada (opções: 0,1  $\mu\text{F}$ ; 1,0  $\mu\text{F}$ ; e 1,7  $\mu\text{F}$  e suas combinações em paralelo). No caso, o valor escolhido foi "C = 0,1  $\mu\text{F}$ ". Assim, a constante de tempo adotada foi " $\tau = 2,5 \text{ ms}$ ". Deste modo, o sistema calcula a média quadrática de todos os pontos que estão no intervalo de tempo determinado por  $\tau$ , gerando com isso um ponto a cada 2,5 ms na saída EA<sub>RMS</sub>.

### (c) Hardware para aquisição de dados

A placa de aquisição de dados (do inglês DAQ – *Data Acquisition*) é o coração do sistema de aquisição. A principal função deste hardware é converter sinais analógicos em sinais digitais e vice-versa, numa velocidade de processamento altíssima.

A DAQ da NATIONAL INSTRUMENTS® modelo NI 6070E (PCI-MIO-16E-1) permite uma taxa de aquisição de até  $1,25 \times 10^6$  pontos por segundo (1,25 MHz) distribuída em 16 possíveis entradas analógicas independentes (8 canais diferenciais) com 12 bits de resolução (1 em  $2^{12}$ ). Mesmo com entradas independentes, a taxa de aquisição é dividida entre os canais da placa, isto é, se forem usados 5 canais, a taxa máxima por canal passa a ser de 250 kHz.

Para evitar o efeito *aliasing* na representação de sinais contínuos analógicos por sinais discretos digitais, a taxa de aquisição deve ser pelo menos duas vezes maior que a máxima frequência do sinal a ser coletado (teorema de Nyquist). Portanto, a máxima frequência possível do sinal que poder ser adquirido num único canal dessa placa é 625 kHz. Por conseguinte, se forem usados 5 canais, a máxima frequência do sinal passa a ser 125 kHz.

#### (d) Computador

O computador usado na aquisição, processamento e tomada de decisões no sistema monitor inteligente consiste de um processador PENTIUM® III 700 MHz, 128 MB de memória de acesso aleatório (RAM – do inglês *random access memory*) e espaço em disco rígido de 10 GB. Além disso, memória de vídeo de 32 MB, monitor de 17" e CD ROM 52x. O ambiente de rede também possibilita a gravação posterior dos dados adquiridos em CD.

#### (e) Software para aquisição de dados

O *software* para a aquisição de dados possibilita a troca de informações entre o computador e a placa DAQ (*hardware*). Sem levar em consideração qual placa se está usando, é preciso enviar informações de configuração ao *hardware* (e.g. taxa de aquisição) e receber informações deste (e.g. dados, mensagens condicionais e mensagens de erro). Também é necessário fornecer à placa DAQ informações que são integradas a outro hardware e/ou a recursos computacionais.

O trabalho foi desenvolvido com auxílio do software MATLAB® (*The MathWorks, Inc.*). Esta ferramenta computacional permite, além da referida troca de informações, efetuar análise numérica, cálculo com matrizes, processamento de sinais e construir gráficos em ambiente amigável. Ambientes de trabalho utilizados:

- Aquisição:** *Data Acquisition Toolbox* possibilita a troca de informações entre o computador e a placa DAQ. Atua sobre a taxa de aquisição, o tempo de aquisição e o *trigger*<sup>43</sup>.

---

<sup>43</sup> Para entradas analógicas, o *trigger* ou disparo é definido como um evento que inicia o armazenamento de dados (memória ou arquivo de disco) em relação ao tempo. Quando ocorre o disparo, um número predefinido de pontos (dados) é adquirido por cada canal e armazenados cronologicamente. Deve-se, portanto especificar este número de pontos. Em geral, para se determinar o tempo de aquisição para cada disparo, aplica-se a fórmula [181]:

$$\text{tempo de aquisição [s]} = \frac{\text{pontos por disparo}}{\text{taxa de aquisição [Hz]}}$$

- ☑ **Pré-processamento:** com a ajuda das ferramentas *Data Analysis*, os índices de monitoramento foram calculados a partir das características extraídas dos sinais de força, vibração e emissão acústica.
- ☑ **Processamento:** *Neural Network Toolbox* permite o processamento paralelo dos índices de monitoramento que atuam como entrada para a rede. A saída da rede fornece valores estimados para a quantificação de desgastes.
- ☑ **Tomada de decisão:** o ambiente de trabalho do MATLAB<sup>®</sup> possibilitou a criação de dois subprogramas: um para verificar se houve fratura na ferramenta e conseqüentemente fornecer a informação para a interrupção do processo e o outro para prognosticar em tempo real o tempo de vida restante à ferramenta baseando-se na saída da RNA.

### (f) Placa de conexão

Uma placa blindada de conexão NATIONAL INSTRUMENTS<sup>®</sup> modelo SCB-68 (68 terminais de conexão) faz a interface entrada  $\Leftrightarrow$  saída (E/S ou I/O) entre os transdutores e a placa DAQ, destacando as 16 entradas analógicas ( $AC_{H00} - AC_{H15}$ ), as 8 interligações I/O digitais ( $DIO_0 - DIO_7$ ) e as 2 saídas analógicas ( $DAC_{0-OUT}$  e  $DAC_{1-OUT}$ ). Combinada com cabos blindados, a placa SCB-68 promove robustez e baixos níveis de ruído nos seus terminais. A figura 8.13 mostra a placa SCB-68.



**Figura 8.13** – Placa de conexão NATIONAL INSTRUMENTS<sup>®</sup> modelo SCB-68

### 8.1.6 Sistema de Medição de Rugosidade

O instrumento de medição da rugosidade gerada na superfície torneada utilizado foi o rugosímetro portátil MITUTOYO® modelo SJ-201 (fig. 8.14). O instrumento pode caracterizar a textura da superfície usinada usando diferentes parâmetros de rugosidade padronizados (segundo, por exemplo, as normas DIN, ISO, ANSI). O princípio de medição baseia-se num sensor de contato mecânico (agulha apalpadora *stylus*) anexado à unidade de detecção que percorre longitudinalmente a superfície usinada da peça. O deslocamento vertical do sensor durante o percurso é processado e digitalmente mostrado no *display* de cristal líquido.



Figura 8.14 – Rugosímetro Portátil MITUTOYO® SJ-201

Um fator muito importante na medição do parâmetro " $R_a$ " é a determinação do valor do comprimento de medição (*cut-off*). Este valor define o comprimento de amostragem que serve de referência para a medição da altura e profundidade das irregularidades no cálculo da rugosidade. A norma ISO 4288 estabelece, em função da estimativa da distância entre os sulcos da superfície usinada, os critérios para a correta seleção do *cut-off*.

## 8.2 Considerações Preliminares

Algumas considerações devem ser realizadas com o intuito dos experimentos serem adequadamente planejados: (a) verificar algumas condições de usinagem de modo a poder avaliar a influência dos parâmetros de corte ( $f$ ,  $v_c$  e  $a_p$ ) nas amplitudes das componentes ortogonais da força de usinagem ( $F_f$ ,  $F_c$  e  $F_p$ ), na amplitude de vibração ( $V_I$ ) e nos valores do desvio médio de rugosidade ( $R_a$ ); (b) determinar o tempo de vida da ferramenta para um critério baseado no estado da mesma (a ser estabelecido).

### 8.2.1 Análise da Influência dos Parâmetros de Corte na Rugosidade e nos Sinais de Força e Vibração

Desejou-se verificar qual o grau de influência dos parâmetros de corte (avanço, velocidade de corte e profundidade de corte) nos sinais adquiridos de força e de vibração, considerando um gume novo em cada combinação de parâmetros. Também, queria se saber qual seria variação da textura da superfície usinada – desvio médio de rugosidade ( $R_a$ ) – com a alteração destes parâmetros. Para tanto, foram utilizados quatro velocidades de corte, três avanços e duas profundidades de corte, conforme recomendações do fabricante e mostrados na tabela 8.2. A variação dos parâmetros possibilitou 24 combinações diferentes, cujos resultados são apresentados na Tabela A.1 (Anexo A.2).

**Tabela 8.2** – Parâmetros de corte escolhidos para a análise


Parâmetros	Valores Escolhidos			
Velocidade de corte $v_c$ [m/min]	180	240	290	350
Avanço $f$ [mm]	0,15	0,22	0,30	
Profundidade de corte $a_p$ [mm]	1,0	1,5		
Meio lubri-refrigerante	Corte a seco			

Os resultados são apresentados nos itens subseqüentes.

#### (a) Força de avanço


A figura 8.15 ilustra a relação entre a força de avanço ( $F_f$ ) e os parâmetros de corte mostrados na tabela 8.2. Pode-se observar nitidamente na figura um aumento de " $F_f$ " com o aumento da profundidade de corte ( $a_p$ ). No caso, o aumento é de 49%, praticamente o mesmo do incremento de " $a_p$ " (50%), já que  $r_\epsilon = 0,8$  mm. Também se pode verificar, com certa clareza, um aumento da intensidade de " $F_f$ " com o aumento do avanço ( $f$ ).

Segundo a teoria, dever-se-ia observar uma redução de " $F_f$ " com o aumento da velocidade de corte ( $v_c$ ) por causa de uma redução da resistência do material em altas temperaturas. Isto foi bem constatado para o avanço de 0,30 mm, onde a quantidade de calor gerada foi maior. Apesar disso, observa-se também para o avanço de 0,15 mm, mas apenas para a profundidade de corte de 1,0 mm.



**Figura 8.15** – Relação entre força de avanço e os parâmetros de corte

A figura 8.16 ilustra a relação entre a força de avanço normalizada ( $NF_f$ ) – vide equação (6.2) – e os parâmetros de corte da tabela 8.2. É possível verificar que “ $NF_f$ ” cresce muito pouco com o aumento de “ $a_p$ ”. No caso, o crescimento é de apenas 3%, bem diferente do incremento de “ $a_p$ ” (50%). O mesmo pode ser dito a respeito da variação de “ $NF_f$ ” com “ $v_c$ ”: ela não é significativa. Por outro lado, nota-se uma diminuição de “ $NF_f$ ” com o aumento do avanço “ $f$ ”.



**Figura 8.16** – Relação entre força de avanço normalizada e os parâmetros de corte

Como a progressão do desgaste da ferramenta é influenciada principalmente por “ $v_c$ ”, depois por “ $f$ ” e por último por “ $a_p$ ”, a estabilidade de “ $NF_f$ ” com a variação de “ $v_c$ ” torna-se um índice de monitoramento muito importante em sistemas TCM.

## (b) Força passiva

A figura 8.17 mostra a relação entre a força passiva ( $F_p$ ) e os parâmetros " $f$ ", " $v_c$ " e " $a_p$ " (tabela 8.2). Pode-se observar claramente um crescimento da intensidade de " $F_p$ " com o acréscimo de " $a_p$ " (" $F_p$ " cresce 35%). Também pode-se ver o aumento de " $F_p$ " quando " $f$ " aumenta. Somente na condição com  $f = 0,30$  mm e  $a_p = 1,5$  mm – maior quantidade gerada de calor – que a diminuição de " $F_p$ " com o aumento de " $v_c$ " mostrou-se evidente.




Figura 8.17 – Relação entre força passiva e os parâmetros de corte

A figura 8.18 ilustra a relação entre a força passiva normalizada ( $NF_p$ ) – vide equação (6.3) – e os parâmetros da tabela 8.2. Observa-se que " $NF_p$ " diminui ligeiramente com o aumento de " $a_p$ " (de aproximadamente 5%). A variação da " $NF_p$ " com " $v_c$ " também não é significativa. No entanto, a diminuição de " $NF_p$ " com o aumento de " $f$ " fica evidenciado.




Figura 8.18 – Relação entre força passiva normalizada e os parâmetros de corte

Desta forma, a estabilidade da " $NF_p$ " com a variação de " $v_c$ " torna-se também um índice de monitoramento muito importante em sistemas TCM.

### (c) Força de corte

A figura 8.19 mostra a relação entre a força de corte ( $F_c$ ) e os parâmetros de corte (tabela 8.2). Pode-se observar claramente o crescimento de " $F_c$ " com o aumento de " $a_p$ ". No caso, o crescimento é de 45%. Também pode se verificar nitidamente um aumento de " $F_c$ " com o aumento de " $f$ ". Já o aumento de " $v_c$ " proporciona uma ligeira redução de " $F_c$ ", praticamente em todos os casos.




Figura 8.19 – Relação entre força de corte e os parâmetros de corte

A figura 8.20 ilustra a relação entre a força de corte normalizada ( $NF_p$ ) – vide equação (6.4) – e os parâmetros de corte da tabela 8.2. Observa-se que a variação de " $NF_c$ " com os aumentos de " $a_p$ " e " $v_c$ " não é significativa. No caso do aumento de " $NF_p$ " com o aumento de " $f$ ", tem-se uma ligeira tendência. Com isso, a estabilidade de " $NF_p$ " com a variação de " $v_c$ " e " $f$ " pode-se tornar também importante um índice de monitoramento.




Figura 8.20 – Relação entre força de corte normalizada e os parâmetros de corte



### (d) Vibração

A figura 8.21 ilustra a relação entre a tensão elétrica de saída do transdutor piezoeletrico usado na aquisição de sinais de vibração e os parâmetros de corte da tabela 8.2. Observando a figura, fica claro que a vibração cresce com o aumento de “f”, já que se pode também verificar um aumento da intensidade da força “F<sub>f</sub>” com este aumento – lembrando que o transdutor está posicionado na direção de avanço (X).




Figura 8.21 – Relação entre o sinal de vibração e os parâmetros de corte

De um modo geral, é possível afirmar para os avanços  $f = 0,15$  mm e  $f = 0,22$  mm que a vibração aumenta: (a) com a diminuição de “v<sub>c</sub>” e (b) com o aumento de “a<sub>p</sub>”. Já para  $f = 0,30$  mm, a vibração oscila; por exemplo, a menor vibração para  $f = 0,30$  mm ocorre com  $v_c = 290$  m/min.

### (e) Rugosidade

O acabamento da superfície depende muito da relação entre avanço (f) e raio de arredondamento de quina (r<sub>ε</sub>). Teoricamente, o desvio médio de rugosidade da superfície torneada (R<sub>a</sub>) é dado pela equação 8.2 [10]:

$$R_a = \frac{1000 \cdot f^2}{18\sqrt{3} \cdot r_\epsilon} \text{ [mm]} \quad (8.2)$$

A figura 8.22 ilustra a relação entre “R<sub>a</sub>”, o valor teórico (para r<sub>ε</sub> = 0,8 mm) e os parâmetros de corte (tabela 8.2). Os valores de rugosidade foram adquiridos pelo rugosímetro SJ-201 (fig. 8.14) utilizando um *cut-off* de 0,8 mm. Observa-se que os valores teóricos assemelham-se bastante aos valores obtidos empiricamente. Algumas variações entre os resul-

tados podem ser explicadas por causa de fatores tais como vibração, deformação do cavaco, fluxo lateral do cavaco etc. E como era de se esperar, " $R_a$ " varia proporcionalmente com " $f$ ". À medida que " $v_c$ " cresce, " $R_a$ " oscila. DINIZ *et al.* [22] explicam este fato afirmando que a oscilação da rugosidade é a resposta que o sistema máquina-peça-ferramenta-dispositivo de fixação dá, em termos de vibração, ao crescimento de " $v_c$ ". Observa-se também que " $a_p$ " não exerce uma influência significativa em " $R_a$ ".




Figura 8.22 – Relação entre o desvio médio de rugosidade e os parâmetros de corte

Observando as semelhanças entre as figuras 8.21 (vibração) e 8.22 (rugosidade), resolveu-se analisar a tendência entre a tensão elétrica de saída do transdutor piezelétrico (tensão elétrica  $V_{RMS}$ ) usado na aquisição de sinais de vibração ( $VI_x$ ) e o desvio médio de rugosidade da superfície torneada ( $R_a$ ). A figura 8.23 ilustra esta relação.




Figura 8.23 – Relação entre o sinal de vibração e o desvio médio de rugosidade

Com uma correlação linear de aproximadamente 89%, pode-se observar para caso analisado que o desvio médio de rugosidade ( $R_a$ ) pode ser estimado de maneira aproximada, a partir de valores monitorados do sinal de vibração captados pelo transdutor piezelétri-

co ( $VI_x$ ), para um eventual controle da qualidade da peça usinada (item 8.1.1), nas condições de usinagem verificadas. Assim, tem-se a representação pela equação (8.3):

$$R_a [\mu\text{m}] \cong 4 \times VI_x [V_{\text{RMS}}] \quad (8.3)$$

Deve-se lembrar que em outras situações os resultados poderiam não ser os mesmos.

### 8.2.2 Determinação Empírica do Tempo de Vida da Ferramenta

A fixação do ponto representativo do fim da vida de uma ferramenta é fundamental no estudo da usinagem em metais. São utilizados diversos critérios para determinar mais ou menos este ponto, dependendo em grande parte das exigências da usinagem (precisão de medidas, grau de acabamento) e do material da ferramenta.

Buscando fixar os parâmetros de corte de modo a poder avaliar o comportamento dos sinais (força, vibração e emissão acústica) e da textura (rugosidade) com a vida da ferramenta e suas falhas, a tabela A.1 (Anexo A.2) mostra os tempos de vida de uma ferramenta de metal-duro, estimados a partir da equação 3.1. Com o intuito de forçar a incidência precoce de falhas, resolveu-se adotar a combinação que resultasse no menor tempo de vida. Então, para  $T = 16,1 \text{ min}$  adotou-se:  $f = 0,3 \text{ mm}$ ;  $v_c = 350 \text{ m/min}$ ;  $a_p = 1,5 \text{ mm}$ ; **torneamento a seco**.

A operação de torneamento realizada em 30 corpos de prova de aço ABNT 1040 (vide item 8.1.1) usando as condições de usinagem do parágrafo anterior possibilitou determinar a curva de vida da ferramenta de metal-duro (item 8.1.2) a partir da avaliação da largura da marca de desgaste de flanco de 15 gumes (pastilhas do mesmo lote). Tomou-se o cuidado de tomar apenas um gume de cada inserto, pois a fratura poderia afetar a integridade da pastilha e influir na vida do gume.

A figura 8.24 ilustra a largura da marca de desgaste de flanco ( $VB$ ) em função do tempo de corte. A área representa 92% dos valores de “ $VB$ ” dos 15 gumes medidos diretamente via câmera CCD (item 8.1.4).

O critério de fim de vida adotado foi baseado no seguinte procedimento: (a) Efetuar-se-ão 32 passes – 16 em cada corpo de prova – totalizando 20,5 min de tempo efetivo de corte. (b) O processo será interrompido se:  $VB_B \geq 300 \mu\text{m}$ , ou  $VB_{\text{max}} \geq 600 \mu\text{m}$ , ou ainda se houver lascamento. (c) Na detecção de lascamento (observado via câmera CCD), dar-se-á mais dois passes para poder avaliar o comportamento dos sinais na situação de avaria.




Figura 8.24 – Curva de vida das ferramentas

A figura 8.25 representa os tempos de vida de cada um dos 15 gumes. O tempo especificado refere-se ao passe imediatamente anterior ao que gerou a fratura na ferramenta. Observa-se que o tempo médio determinado empiricamente ( $T = 16,26$  min) corresponde ao valor teórico estimado ( $T = 16,05$  min) pela equação (3.1).




Figura 8.25 – Tempos de vida dos gumes analisados

Dois casos devem ser analisados separadamente:

- Caso 1: Comportamento Determinístico.** Os 10 gumes que ficaram acima da média (1-5; 9; 12-15) apresentaram inicialmente desgastes regulares (uniforme), seguidos por desgastes irregulares e lascamento. Possivelmente, a uniformidade do desgaste no início caracterizou-se pelo efeito da abrasão e as irregularidades na marca de desgaste por adesão e sobrecarga mecânicas (que possivelmente geraram o lascamento), como afirmam CHILDS *et. al* [16]. A vida da ferramenta superou as expectativas, podendo-se então dizer que o descarte destas pastilhas aos 16 minutos leva ao desperdício.

- ☑ **Caso 2: Comportamento Aleatório.** Os 5 gumes que ficaram abaixo da média (6-8; 10-11) apresentaram irregularidades no desgaste já no início do tempo de vida, e o lascamento ocorreu precocemente (antes do tempo esperado). Então, a adesão foi proeminente na determinação do fim de vida da ferramenta. Como ela ficou abaixo dos 16 minutos, uma quebra inesperada possivelmente resulta num refugo da peça usinada, gerando com isto desperdício.

Tomando como base os gumes 9 e 10, observa-se uma diferença de aproximadamente 90% no tempo de vida entre eles. Para o **Caso 1** (onde se enquadra o gume 9), um modelo matemático pode estimar o tempo de vida restante da ferramenta de corte a partir do valor atual da largura da marca de desgaste de flanco, pois este se apresenta como uma falha contínua. Já no **Caso 2** (e.g. gume 10), a avaria, por ser um evento transitório, não pode ser descrita por uma função matemática explícita. Além disso, é detectada somente após o ocorrido [42]. E como já citado anteriormente no Capítulo 6 por Moriwaki [63], sua detecção é tão (ou até mais) importante que a estimativa de desgastes.

### 8.3 Ensaio Realizados e Resultados Alcançados

Visando determinar as regras de inferência sobre o estado da ferramenta a partir das informações extraídas dos sinais adquiridos, foram feitas algumas experimentações. No caso, utilizaram-se os parâmetros adotados no item 8.2.2 (tabela 8.3).

**Tabela 8.3** – Parâmetros de corte escolhidos para a determinação dos índices de monitoramento

Parâmetros	Valores Adotados
Velocidade de corte $v_c$ [m/min]	350
Avanço $f$ [mm]	0,30
Profundidade de corte $a_p$ [mm]	1,5
Meio lubri-refrigerante	Corte a seco

Analisou-se a capacidade de detecção de avariais (lascamento e quebra) e a estimativa da largura da marca de desgaste de flanco (VB) dos sinais de força, vibração e emissão acústica dentro das limitações do sistema. Por fim, para elucidar os resultados, avaliou-se a textura da superfície usinada, relacionando a amplitude do desvio médio geométrico (rugosidade “ $R_a$ ”) com o valor de “VB”.

### 8.3.1 Análise de Sinais de Força

A figura 8.26 mostra um esquema para a medição em torneamento das três componentes ortogonais da força de usinagem ( $F_r$ ,  $F_p$  e  $F_c$ ) utilizando um dinamômetro piezelétrico, usualmente chamado de plataforma piezelétrica (vide figura 8.7).




Figura 8.26 – Sistema de medição de força em torneamento

As parcelas estáticas e dinâmicas das três componentes são medidas simultaneamente. Os amplificadores de carga (vide figura 8.10) encarregam-se de converter cargas elétricas (em coulomb) geradas pela plataforma em sinais de tensão elétrica (em volts) proporcionais à carga, filtrar estes sinais (filtro passa-altas FPA: eliminar ruídos de baixa frequência gerados na rotação da peça e/ou do motor) e em seguida amplificá-los, para somente depois serem devidamente tratados e analisados no microcomputador.

Na coleta dos pontos, a frequência de aquisição foi configurada para 50 kHz por canal, ou seja, captação de 1 ponto a cada 20  $\mu$ s. A constante de tempo adotada para o cálculo dos valores de tensão elétrica " $V_{RMS}$ " via MATLAB<sup>®</sup> foi " $\Delta t$ " = 4 ms. Deste modo, o sistema calcula a média quadrática de " $n$ " = 200 pontos que estão no intervalo de tempo determinado por " $\Delta t$ ", gerando com isso um ponto a cada 4 ms na saída [equação (5.3)]. Ajustando o fator de escala dos amplificadores de carga para  $S = 200$ , tem-se que 1 V de sinal equivale a 200 N. Assim, as curvas das forças em função do tempo de corte puderam ser geradas.


Para que se pudesse comprovar a precisão (boa repetitividade) e a exatidão (boa tendência) dos resultados, foram feitos 4 (quatro) ensaios de fim de vida da ferramenta de

metal-duro (subitem 8.1.2) no torneamento do aço ABNT 1040 (subitem 8.1.1). O critério de fim de vida adotado baseou-se no mesmo procedimento do subitem 8.2.2.

O desgaste de flanco foi medido diretamente (câmera CCD) ao final de cada passe executado. Os sinais foram adquiridos nos primeiros 10 segundos de cada passe (com exceção do gume 4 – detalhes na parte (b) deste subitem). Os valores médios calculados neste período foram considerados na geração dos gráficos em função do tempo de vida da ferramenta de corte (em minutos).

### (a) Estimativa de Desgastes

A figura 8.27 mostra a largura da marca de desgaste de flanco (VB) em função do tempo de usinagem para os 4 gumes verificados. Nos gumes, os desgastes mantiveram-se praticamente uniformes até  $VB \cong 170 \mu\text{m}$ . A partir daí, os gumes 1, 2 e 3 começaram a se tornar irregulares até  $VB \cong 300 \mu\text{m}$ , quando o processo foi interrompido. No gume 4, o desgaste de flanco manteve-se irregular até os lascamentos ocorrerem em  $VB \cong 225 \mu\text{m}$ .



**Figura 8.27** – VB em função do tempo de corte para 4 gumes

As figuras 8.28, 8.29 e 8.30 mostram respectivamente os gráficos das forças de avanço, passiva e de corte em função do tempo de usinagem para os gumes em questão. Nota-se no gume 4 um crescimento brusco das três componentes após 16 minutos de usinagem (diferente dos gumes 1, 2 e 3 que apresentam crescimento contínuo e uniforme).




Figura 8.28 – Força de avanço em função do tempo de usinagem




Figura 8.29 – Força passiva em função do tempo de usinagem

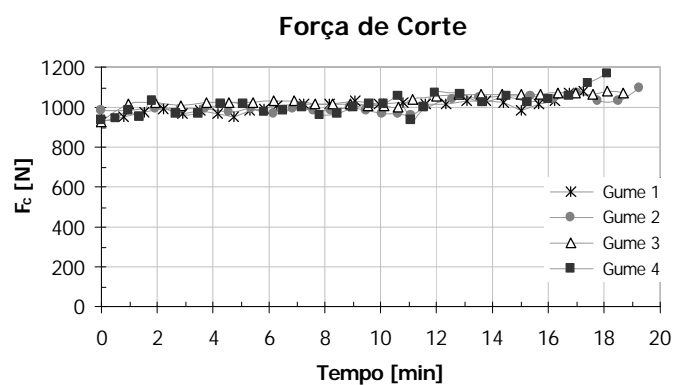


Figura 8.30 – Força de corte em função do tempo de usinagem

Analisando o percentual de crescimento das componentes da força de usinagem – em relação ao valor inicial com gume novo – com a largura de desgaste de flanco para os gumes 1, 2 e 3 (gráficos no anexo A.3), foi possível estimar “VB” a partir das equações (8.4), (8.5) e (8.6) com correlação linear superior a 99% para “F<sub>f</sub>” e “F<sub>p</sub>” e 95% para “F<sub>c</sub>”.



$$\checkmark F_f: \quad VB_{est.} = 0,017 + 0,104 \cdot (0,028 + 19,2 \cdot P_{F_f})^{0,5} \quad (8.4)$$

$$\checkmark F_p: \quad VB_{est.} = 0,024 + 0,085 \cdot (0,078 + 23,6 \cdot P_{F_p})^{0,5} \quad (8.5)$$


$$\checkmark F_c: \quad VB_{est.} = -0,448 + 1,45 \cdot (0,095 + 1,38 \cdot P_{F_c})^{0,5} \quad (8.6)$$

Tomando como exemplo um aumento de 25% da força passiva em relação ao seu valor inicial ("P<sub>Fp</sub>" = 0,25), o valor estimado da largura da marca de desgaste de flanco (com uma correlação linear de 99,1%) será "VB<sub>est.</sub>" ≅ 0,225 mm. A tabela 8.4 resume os resultados. Confirmando a teoria, as forças "F<sub>f</sub>" e "F<sub>p</sub>" mostraram-se mais sensíveis a "VB" que "F<sub>c</sub>".


**Tabela 8.4** – Relação entre o aumento percentual das componentes da força de usinagem e o valor de VB

Valor Estimado VB <sub>est</sub>	Aumento Percentual dos Valores das Componentes		
	AVANÇO (P <sub>Ff</sub> )	PASSIVA (P <sub>Fp</sub> )	CORTE (P <sub>Fc</sub> )
0,10 mm	3%	4,5%	3,5%
0,15 mm	9%	11%	5,5%
0,20 mm	16%	20%	7,5%
0,25 mm	26%	31%	10%
0,30 mm	38%	45%	12,5%


As figuras 8.31, 8.32 e 8.33 mostram respectivamente os gráficos das forças normalizadas de avanço, passiva e de corte – equações (6.2), (6.3) e (6.4) – em função do tempo de usinagem para os gumes em questão. Como se viu anteriormente, pode-se notar no gume 4 uma variação mais acentuada da tendência nas três componentes após 16 minutos de usinagem (diferente dos gumes 1, 2 e 3 que apresentam uma tendência regular).



**Figura 8.31** – Força de avanço normalizada em função do tempo de usinagem



**Figura 8.32** – Força passiva normalizada em função do tempo de usinagem



**Figura 8.33** – Força de corte normalizada em função do tempo de usinagem

Analisando agora o percentual de variação das componentes normalizadas da força de usinagem – em relação ao valor inicial – com o desgaste de flanco para os gumes 1, 2 e 3 (vide gráficos no anexo A.3), foi possível estimar “VB” a partir das equações (8.7), (8.8) e (8.9) com correlação linear igual ou superior a 98%.

$$\checkmark \quad NF_f: \quad VB_{est.} = 0,032 + 0,175 \cdot (0,033 + 11,4 \cdot P_{NF_f})^{0,5} \quad (8.7)$$

$$\checkmark \quad NF_p: \quad VB_{est.} = 0,039 + 0,118 \cdot (0,106 + 16,9 \cdot P_{NF_p})^{0,5} \quad (8.8)$$



$$\checkmark \quad NF_c: \quad VB_{est.} = 0,055 + 0,211 \cdot (0,068 - 9,47 \cdot P_{NF_c})^{0,5} \quad (8.9)$$

Exemplificando, um aumento de 15% da força de avanço normalizada em relação ao seu valor inicial (“ $P_{NF_f}$ ” = 0,15) ter-se-á um valor estimado do desgaste (correlação linear de 99%) de “ $VB_{est.}$ ”  $\cong$  0,26 mm. A tabela 8.5 resume os resultados encontrados. Observa-se que a força normalizada “ $NF_p$ ” mostra-se evidentemente mais sensível a “VB” que “ $F_f$ ” e “ $F_c$ ”.

**Tabela 8.5** – Relação entre a variação percentual das componentes normalizadas e o valor de VB

Valor Estimado $VB_{est}$	Variação Percentual das Componentes Normalizadas		
	AVANÇO ( $P_{Nff}$ )	PASSIVA ( $P_{Nfp}$ )	CORTE ( $P_{Nfc}$ )
0,10 mm	1,0%	1,0%	+0,2%
0,15 mm	3,7%	4,6%	-1,4%
0,20 mm	7,8%	10,4%	-4,3%
0,25 mm	13,3%	18,3%	-8,3%
0,30 mm	20,3%	28,4%	-13,5%

As figuras 8.34, 8.35 e 8.36 mostram respectivamente os gráficos das relações “ $R_1$ ”, “ $R_2$ ” e “ $R_3$ ” – equações (6.5), (6.6) e (6.7) – em função do tempo de usinagem para os gumes em questão. Como já era de se esperar, observou-se no gume 4 uma variação mais acentuada do crescimento após 16 minutos de usinagem (diferente dos gumes 1, 2 e 3 que apresentaram um crescimento uniforme).

**Figura 8.34** – Relação “ $R_1$ ” em função do tempo de usinagem**Figura 8.35** – Relação “ $R_2$ ” em função do tempo de usinagem

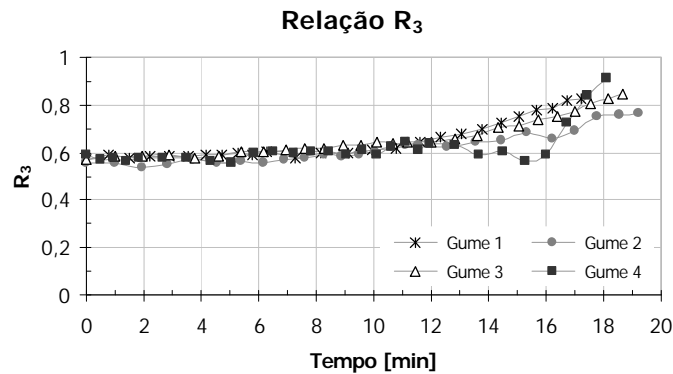


Figura 8.36 – Relação “R<sub>3</sub>” em função do tempo de usinagem

Observando o percentual de variação das relações “R<sub>1</sub>”, “R<sub>2</sub>” e “R<sub>3</sub>” – tomando o gume novo como referência – com o desgaste de flanco para os gumes 1, 2 e 3 (gráficos no anexo A.3), foi possível estimar “VB” a partir das equações (8.10), (8.11) e (8.12) com correlação linear superior a 98%.

$$\checkmark R_1: \quad VB_{\text{est.}} = 0,037 + 0,112 \cdot (0,108 + 17,8 \cdot P_{R_1})^{0,5} \quad (8.10)$$

$$\checkmark R_2: \quad VB_{\text{est.}} = 0,040 + 0,088 \cdot (0,205 + 22,7 \cdot P_{R_2})^{0,5} \quad (8.11)$$

$$\checkmark R_3: \quad VB_{\text{est.}} = 0,039 + 0,096 \cdot (0,167 + 20,9 \cdot P_{R_3})^{0,5} \quad (8.12)$$

Tomado como exemplo um aumento de 20% de “R<sub>3</sub>” em relação ao seu valor inicial (“P<sub>R<sub>3</sub></sub>” = 0,20), o valor estimado do desgaste será “VB<sub>est.</sub>” ≅ 0,24 mm (para uma correlação linear de 99%). A tabela 8.6 resume os resultados encontrados.

Tabela 8.6 – Relação entre as variações percentuais de “R<sub>1</sub>”, “R<sub>2</sub>” e “R<sub>3</sub>” e o valor de “VB”

Valor Estimado VB <sub>est.</sub>	Variação Percentual das Relações		
	R <sub>1</sub> (P <sub>R1</sub> )	R <sub>2</sub> (P <sub>R2</sub> )	R <sub>3</sub> (P <sub>R3</sub> )
0,10 mm	1,2%	1,2%	1,2%
0,15 mm	5,1%	6,0%	5,6%
0,20 mm	11,3%	13,7%	12,7%
0,25 mm	19,8%	24,3%	22,3%
0,30 mm	30,3%	37,5%	34,5%

As variações das relações com “VB” foram bem evidenciadas, onde “R<sub>2</sub>” confirma-se como a mais sensível, seguida de “R<sub>3</sub>”.

## (b) Detecção de Avarias

Tomando o gume 4 como referência para análise do comportamento das forças com a fratura da ferramenta, foi possível verificar as características dos sinais adquiridos em função do tempo de vida.

As figuras 8.37, 8.38, 8.39 e 8.40 mostram respectivamente os valores das componentes da força de usinagem em função do tempo para o gume 4 nas situações: novo, desgastado, lascado e quebrado.




Figura 8.37 – Forças após 30 segundos




Figura 8.38 – Forças após 13 minutos




Figura 8.39 – Forças após 17 minutos




Figura 8.40 – Forças após 18 minutos

O desgaste no flanco da ferramenta (gume 4) manteve-se praticamente uniforme até aproximadamente 12 minutos, quando se iniciou um desgaste de entalhe. Até então, a aquisição ocorria durante os 10 primeiros segundos de cada passe.

A partir dos 12 minutos, passou-se a se coletar os primeiros 30 segundos de cada passe, já que o desgaste irregular no flanco da ferramenta ( $VB \cong 170 \mu\text{m}$ ) começou a predominar, mantendo-se assim até os lascamentos (entre 16min45s e 17min26s de vida), com

VB próximo de 225  $\mu\text{m}$ . Após o aparecimento dos lascamentos, passou-se a se considerar a aquisição ao longo de todo o passe (cerca de 40 segundos).

Os fragmentos desprendidos causaram um escalonamento dos valores das forças (subida por “degraus”). Após a fragmentação, as forças continuaram crescendo de maneira abrupta até a interrupção do processo (quebra do gume 4). Para ilustrar este fato, a figura 8.41 mostra o crescimento percentual das componentes em função do tempo de corte.




Figura 8.41 – Variação percentual das forças em função do tempo de usinagem

O que se pode concluir a respeito da detecção da fratura através de sinais de força é que as amplitudes dos sinais alteram-se de maneira significativa com os lascamentos e, principalmente, com a quebra. Mais uma vez, a força passiva (ou de profundidade) mostra-se mais sensível a esta ocorrência.

### 8.3.2 Análise de Sinais de Vibração

A figura 8.42 mostra um esquema para a medição em torneamento dos sinais de vibração utilizando um transdutor piezolétrico (vide fig. 8.8). O sinal de vibração na direção de avanço (X) mostra-se mais sensível ao desgaste da ferramenta de corte em torneamento que nas direções de profundidade ( $V_{1y}$ ) e de corte ( $V_{1z}$ ) [193].

No sistema de medição, o pré-amplificador (vide fig. 8.11) encarrega-se de converter cargas elétricas (em coulomb) geradas pelo cristal piezolétrico com a deformação em sinais de tensão elétrica (em volts) proporcionais à carga, filtrar estes sinais (filtro passa-faixa de 5 a 25 kHz) e em seguida amplificá-los, para somente depois serem devidamente tratados e analisados no microcomputador.

Na coleta dos pontos, a frequência de aquisição foi configurada para 50 kHz por canal, ou seja, captação de 1 ponto a cada 20  $\mu\text{s}$ . A constante de tempo adotada para o cálculo dos valores de tensão elétrica " $V_{\text{RMS}}$ " via MATLAB<sup>®</sup> foi " $\Delta t$ " = 4 ms. Deste modo, o sistema calcula a média quadrática de " $n$ " = 200 pontos que estão no intervalo de tempo determinado por " $\Delta t$ ", gerando com isso um ponto a cada 4 ms na saída [equação (5.3)].




Figura 8.42 – Sistema de medição de vibração em torneamento

No ensaio de fim de vida do gume 4, o sinal de vibração foi adquirido simultaneamente às componentes da força de usinagem. Assim, o procedimento de medição do desgaste de flanco e o intervalo de coleta de pontos foram comentados no subitem 8.3.1 (b).

### (a) Estimativa de Desgastes

Considerando o gume 4 na análise da vibração em função do desgaste, as características dos sinais adquiridos em função do tempo de vida foram verificadas. Assim, as figuras 8.43, 8.44, 8.45 e 8.46 mostram respectivamente o comportamento da vibração em função do tempo para o gume 4 nas situações: novo, desgastado, lascado e quebrado.

Foi dito anteriormente que o desgaste de flanco manteve-se praticamente uniforme até aproximadamente 12 minutos, quando se iniciou o entalhe. A irregularidade do desgaste no flanco da ferramenta começou a predominar a partir de  $VB \cong 170 \mu\text{m}$ . Nos sinais, observa-se claramente uma variação das amplitudes das parcelas estáticas e dinâmicas de um caso (gume novo) para outro (gume desgastado).

Entre 16min45s e 17min26s de vida, iniciaram-se os lascamentos com “VB” aproximadamente igual a 225  $\mu\text{m}$ . Aparentemente, a amplitude da parcela dinâmica do sinal passa a apresentar um comportamento mais aleatório com a fragmentação do gume. O crescimento acelerado deu-se após a quebra da ferramenta ser constatada.




Figura 8.43 – Vibração após 30 segundos




Figura 8.44 – Vibração após 13 minutos




Figura 8.45 – Vibração após 17 minutos




Figura 8.46 – Vibração após 18 minutos

A figura 8.47 mostra a representação das parcelas estática e dinâmica do sinal de vibração (intervalo de confiança de 95%) em função do tempo de usinagem.

Pode-se verificar na figura 8.47 um crescimento do valor médio (parcela estática) com o tempo de usinagem. A parcela dinâmica tem um aumento a partir dos 14 minutos de usinagem e mantém esta tendência até a ocorrência dos lascamentos. Após os lascamentos, verificou-se uma diminuição bem acentuada dos valores das parcelas ( $\cong$  17 minutos). Depois que houve a quebra do gume, as parcelas (estática e dinâmica) cresceram rapidamente até a interrupção do processo.






Figura 8.47 – Vibração em função do tempo de corte

A figura 8.48 compara o crescimento percentual da força passiva e da vibração em função do desgaste de flanco para as condições de usinagem da tabela 8.3. É possível verificar nitidamente os comportamentos distintos dos sinais após os lascamentos do gume entre 16min45s e 17min26s (área indicada menor): a vibração tende a diminuir enquanto a força tende a aumentar. Após os lascamentos, a tendência crescente foi constatada para ambas.




Figura 8.48 – Variação percentual da vibração e da força passiva em função do tempo de corte

## (b) Detecção de Avarias

Tanto o instante dos lascamentos quanto da quebra puderam ser observados através da análise da assimetria e da curtose da distribuição- $\beta$  do sinal de vibração (tensão elétrica  $V_{RMS}$ ) em função do tempo de corte.

A rotação não ultrapassou 2300 rpm. Assim, um giro da peça no torno equivale a, no mínimo, 26 ms. Desta forma, como foi gerado um ponto a cada 4 ms (tensão elétrica  $V_{RMS}$  via MATLAB®), um giro pode ser representado por um mínimo de 6 pontos. Tomando

amostras concatenadas de 10 pontos (vide fig. 8.49), foi possível calcular a média e o desvio-padrão de cada amostra. Assim, cada resultado foi gerado a cada 16 ms.




Figura 8.49 – Amostragem concatenada de pontos ( $V_{RMS}$ ) em função do tempo de corte

Usando as equações de (5.5) a (5.10), verificou-se a assimetria e a curtose nas quatro condições do gume 4 avaliadas anteriormente: novo, desgastado, lascado e quebrado – figuras 8.50, 8.51, 8.52 e 8.53 respectivamente.




Figura 8.50 – “ $S_{\beta}$ ” e “ $K_{\beta}$ ” após 30 segundos




Figura 8.51 – “ $S_{\beta}$ ” e “ $K_{\beta}$ ” após 13 minutos

Para a figura 8.50, as amplitudes mantêm-se próximas de zero, sem nenhum pico. Na figura 8.51, vêem-se picos negativos de curtose de grande amplitude, originados pelo comportamento não-determinístico da parcela dinâmica do sinal de vibração. Este comportamento é resultado dos microlascamentos gerados por adesão ou trincas térmicas no flanco da ferramenta. **Observação:** quanto maior a dispersão de valores em relação ao valor médio, menor o valor de “ $K_{\beta}$ ”.




Figura 8.52 – “S<sub>β</sub>” e “K<sub>β</sub>” após 17 minutos




Figura 8.53 – “S<sub>β</sub>” e “K<sub>β</sub>” após 18 minutos

Com relação à figura 8.52, os picos apresentam uma amplitude ainda maior, se comparados com os gerados por microlascamentos (fig. 8.51). Observando as figuras 8.39 e 8.45, observa-se um escalonamento dos sinais de força e um comportamento aleatório do sinal de vibração. Estes comportamentos evidenciam o que gerou os picos de curtose e o maior de assimetria (negativo). **Observação:** o pico de “S<sub>β</sub>” mostra que o valor modal (aparece com maior frequência) é maior que o valor médio.

Já na figura 8.53, o pico de larga amplitude (curtose) mostra o momento da quebra catastrófica da ferramenta: aos 18,4842 min ou 18 min 29 s ( $53 \pm 8$ ) ms.

### 8.3.3 Análise de Sinais de Emissão Acústica

O procedimento típico de processamento de sinais de EA em torneamento pode ser visualizado através do esquema ilustrativo da figura 8.54. No sistema de medição, o BM-12 (vide fig. 8.12) encarrega-se de fazer o condicionamento do sinal de maneira semelhante ao pré-amplificador PROMETEC® GDV (os transdutores de vibração e EA são piezelétricos: a diferença está na faixa de frequência de operação); em seguida os sinais são tratados e analisados no microcomputador.

Pode-se observar na figura 8.54 que o sensor de EA fica posicionado o mais próximo possível da zona de corte. Como a presença de ruídos de baixa frequência é inevitável mesmo que não sejam considerados na análise do estado da ferramenta de corte, o sinal total precisa ser amplificado para só depois ser desconsiderada a parcela de baixa frequência através de um filtro passa-altas (FPA 50 ou 100 kHz). Às vezes, o sinal de EA é novamente filtrado (FPB 500 kHz) de modo a eliminar ruídos de alta frequência (e.g. centelhas elétricas) ou evitar o efeito *aliasing*. O sinal bruto (EA<sub>RAW</sub>) é então demodulado na forma de valor mé-

dio ou  $EA_{RMS}$  para obter um sinal de baixa frequência para só depois ser devidamente tratado e analisado no microcomputador [194; 195]. A figura 8.55 mostra exemplos de sinais de EA bruto (RAW) e demodulado (RMS) após as filtragens.

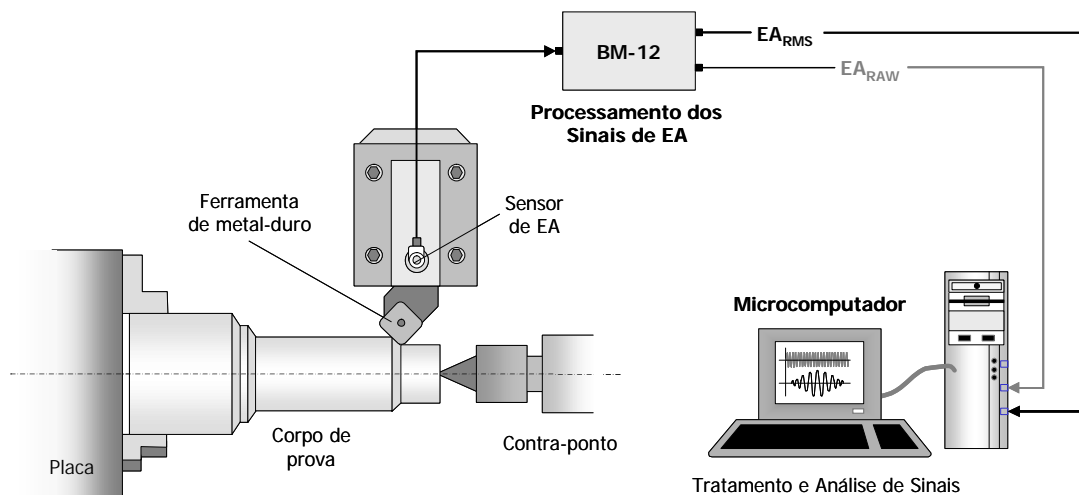


Figura 8.54 – Sistema de medição de emissão acústica em torneamento




Figura 8.55 – Sinais de EA após filtragens (FPA e FPB) [194; 195]

A emissão acústica foi considerada um caso a parte neste trabalho, já que surgiram alguns contratempos que impediram uma análise mais ampla. Tais problemas podem ser a seguir sumariados:

- ☑ Primeiramente acreditou-se que o sistema da PROMETEC<sup>®</sup>, formado por um transdutor piezelétrico modelo AEW 100 (faixa de 8 a 800 kHz) e um pré-amplificador com filtros *plug-in* (FPA de 50 kHz, FPA de 100kHz, FPF de 100 a 300 kHz), ganho ajustável (de 2 a 60 dB) e saída  $V_{RMS}$  (não citados no item 8.1, pois não foram usados posteriormente), não estava fornecendo as informações condizentes com o estado atual da ferramenta de corte. Pensou-se em verificar o sinal bruto de EA, mas não houve como descobrir onde no pré-amplificador efetuava-se o processamento do sinal bruto ( $EA_{RAW}$ ) para o si-

nal tratado ( $EA_{RMS}$ ) e qual era a constante de tempo usada neste processamento – apesar de vários contatos com o fabricante, sem resposta. Foram trocados os filtros *plug-in*, foram alterados os ganhos, e não foi possível constatar alguma correlação com “VB”.


- ☑ A tentativa posterior foi utilizar o sistema da SENSIS<sup>®</sup>, formado por um transdutor piezoelétrico e um sistema monitor modelo BM-12, gentilmente cedido por empréstimo ao LMP para que tais dúvidas fossem sanadas e os experimentos fossem executados. Após um grande número de verificações (alterando os FPA's de 50 e 100 kHz, ajustando os ganhos e observando os sinais  $EA_{RAW}$  e  $EA_{RMS}$ ), constatou-se que o canal da placa de aquisição (PCI-MIO-16E-1, item 8.1.5.c) onde o sinal de EA estava entrando apresentava problemas. Detectado o problema, uma nova etapa iniciou.
- ☑ O sensor foi posicionado sobre a haste da ferramenta, na direção de corte (eixo Z). Acreditando que não haveria qualquer possibilidade de interferência no sinal com a colisão dos cavacos contra o sensor, os ensaios foram realizados sem que qualquer proteção fosse providenciada. Como o transdutor da SENSIS<sup>®</sup> atua em frequências superiores a 1 kHz, e mesmo usando um FPA de 50 kHz (ou até de 100 kHz), o choque dos cavacos (em lascas) contra o mesmo ficou bem evidenciado no sinal detectado (ruídos no sinal, até o cavaco assumir o formato espiral – a geometria do gume alterou-se com o desgaste, fazendo com que o quebra-cavaco perdesse sua eficiência).
- ☑ Depois, precisava-se saber qual a frequência do sinal de EA necessária para a detecção de avarias pelo transdutor, visto que o índice de monitoramento obtido através da extração da característica do sinal no domínio da frequência (FFT) mostra, para uma determinada faixa de frequência, valores crescentes de amplitude da tensão elétrica com o aumento da largura da marca de desgaste de flanco. Usando o FPA de 50 kHz e fazendo a aquisição do sinal de EA usando a taxa máxima permitida pela placa (1,25 MHz) em um segundo de coleta, tomada no início de cada passe, verificou-se que a variação de amplitudes ocorria numa faixa de frequências entre 100 e 150 kHz<sup>44</sup>.

### 8.3.4 Análise de Rugosidade

A figura 8.56 ilustra de maneira clara o comportamento do desvio médio de rugosidade da superfície torneada ( $R_a$ ) em função do tempo para o gume 4.


---

<sup>44</sup> Infelizmente, os dados destes experimentos extraviaram-se por causa de uma falha no HD do computador pessoal do autor. Uma falha ainda maior foi não ter armazenado tais informações num CD, o qual evitaria tais contratempos e constrangimentos.



**Figura 8.56** – “ $R_a$ ” em função do tempo para o gume 4

Analisando a figura 8.56, fica evidente a degradação da superfície usinada – quantificada por “ $R_a$ ” – com a progressão das falhas na ferramenta de corte: desgaste, seguido de lascamento e, por fim, a quebra. A figura 8.57 ilustra a variação da rugosidade com o desgaste de flanco médio. Vale lembrar aqui que, em outras situações, os resultados poderiam não ser os mesmos.



**Figura 8.57** – “ $R_a$ ” em função de VB para o gume 4

## 8.4 Determinação das Regras de Inferência

O objetivo aqui é associar os índices de monitoramento com o estado da ferramenta de corte durante o processo de torneamento. Apesar da rugosidade ser uma variável dependente de saída que tem uma relação direta significativa com as falhas (no flanco) da ferramenta, o processo precisa ser interrompido para que a medição (*off-line*) seja efetuada.

Como explicam DINIZ *et al.* [22], normalmente não se dispõe de rugosímetro ao lado da máquina. Além disso, a comparação da rugosidade da peça usinada com a peça-padrão que tenha rugosidade limite estabelecida em projeto é um procedimento extremamente impreciso. Assim, não se pode decidir objetivamente sobre o momento ótimo da troca da ferramenta. O resultado, geralmente, é o grande desperdício de ferramentas, já que o fim de vida é estabelecido de maneira bem conservadora, de modo a não estragar a peça e não causar qualquer outro dano à produção.

Deste modo, e seguindo a proposta inicial do trabalho, a estimativa da largura do desgaste de flanco e a detecção de avarias devem correlacionar-se indiretamente com índices de monitoramento *on-line* num sistema monitor inteligente.

#### 8.4.1. Estimativa da Largura do Desgaste de Flanco

As componentes da força de usinagem, em especial a passiva (eixo Y), apresentam uma excelente correlação com a largura da marca de desgaste de flanco. Tomando o sinal de referência com o gume novo (100%), a ferramenta poderia ser substituída, por exemplo, quando a força passiva atingir uma amplitude de 145% e/ou quando a força de avanço alcançar 138%, ou ainda quando a força de corte chegar a 112% (tabela 8.4).

Nas considerações preliminares, foi possível observar claramente as perturbações causadas pelas variações na velocidade de corte, no avanço e na profundidade de corte. Estas variações podem definitivamente gerar a mesma ordem de magnitude que os diferentes níveis de desgastes e fraturas em ferramentas de corte (figuras 8.15, 8.17 e 8.19). A velocidade de corte ( $v_c$ ) é o parâmetro que mais influencia no desgaste, pois com o incremento desta, a energia (calor) que é atribuída ao processo aumenta, sem que haja um crescimento da área da ferramenta que recebe esta energia [22].

Para eliminar a influência da variação da velocidade de corte, a normalização das componentes de avanço, passiva e corte (figuras 8.16, 8.18 e 8.20) foram também analisadas. Nas considerações preliminares, observou-se com a normalização uma alteração de amplitude (diminuição para "Ff" e "Fp" – aumento para "Fc") com o aumento da taxa de avanço e variações pouco significativas da velocidade e da profundidade de corte. Assim, tomando o sinal de referência com o gume novo (100%), a ferramenta poderia ser substituída, por exemplo, quando a força passiva normalizada atingir uma amplitude de 128% e/ou quando a de avanço normalizada alcançar 120%, ou ainda quando a de corte normalizada chegar a 86% (tabela 8.5).

Nos casos da vibração e da emissão acústica, observou-se apenas uma tendência crescente dos valores de tensão elétrica ( $V_{RMS}$ ) com o aumento da largura da marca de desgaste de flanco. Não foi possível determinar um modelo que pudesse correlacionar eficientemente o sinal adquirido com o valor do desgaste "VB".

### 8.4.2. Detecção de Avarias (lascamento e quebra)

O tratamento de sinais de vibração no domínio do tempo através dos valores calculados de assimetria e curtose da distribuição- $\beta$  mostrou-se eficaz na detecção de avarias na ferramenta de corte em torneamento. Os valores obtidos ao longo da vida da ferramenta podem ser sumariados nos subitens subseqüentes.

#### (a) Assimetria ( $S_\beta$ ) do sinal de vibração

Os valores de assimetria ( $S_\beta$ ) positivos ou negativos refletem o grau de desvio (ou afastamento) da simetria da distribuição- $\beta$  [89]. Depois de uma análise criteriosa dos gumes ao longo do tempo, chegou-se à conclusão que, para a detecção de fratura, tem-se:

- $S_\beta < 0 \Rightarrow$  quanto mais negativo o valor, maior a diferença entre a moda e a média. Esta diferença dá indícios de que houve avaria.
- $10^0 \leq S_\beta < 10^1 \Rightarrow$  trincas e microlascamentos do gume.
- $10^1 \leq S_\beta < 10^2 \Rightarrow$  pequenos lascamentos do gume.
- $10^2 \leq S_\beta < 10^3 \Rightarrow$  grandes lascamentos do gume.
- $S_\beta \geq 10^3 \Rightarrow$  quebra do gume.

#### (b) Curtose ( $K_\beta$ ) do sinal de vibração

Os valores de curtose ( $K_\beta$ ) representam o grau de achatamento da distribuição- $\beta$ . Se o valor for positivo, a distribuição tem o topo pontiagudo (*leptocúrtica*); se for negativo, tem o topo achatado (*platicúrtica*) [89]. Assim, na detecção de avarias, pôde-se concluir a partir da análise dos gumes que:

- $K_\beta < 0 \Rightarrow$  quanto mais negativo o valor, maior a dispersão dos valores em torno da média. Esta dispersão aumenta significativamente com a ocorrência de lascamentos.
- $10^0 \leq K_\beta < 10^2 \Rightarrow$  perturbações aleatórias (e.g. inclusões não-metálicas na peça).



- ☑  $10^2 \leq K_\beta < 10^3 \Rightarrow$  trincas e microlascamentos do gume.
- ☑  $10^3 \leq K_\beta < 10^4 \Rightarrow$  pequenos lascamentos do gume.
- ☑  $10^4 \leq K_\beta < 10^5 \Rightarrow$  grandes lascamentos do gume.
- ☑  $K_\beta \geq 10^5 \Rightarrow$  quebra do gume.

Já para a emissão acústica, os resultados não ficaram evidenciados devido aos contrastes citados no subitem 8.3.3. Mesmo assim, insistiu-se em manter a aquisição do sinal de EA na implementação do sistema monitor inteligente.

## 8.5. Testes Iniciais com RNA via MATLAB<sup>®</sup>

É praticamente impossível determinar uma arquitetura efetiva para uma rede neural artificial (número de camadas e de neurônios em cada camada) a partir das especificações de um problema. Isto deve ser feito analítica e/ou empiricamente. A suposição teórica de que uma determinada rede neural seja a solução para um certo conjunto de dados que se apresente, pode causar uma grande frustração [179].

A medida de desempenho da rede (generalização) é feita usando um conjunto de dados de teste não utilizados durante o treinamento. A generalização é considerada “boa” quando a aplicação de um conjunto de dados de teste resulta em valores corretos. Para tanto, foram testadas cinco configurações de redes diretas com os algoritmos de treinamento por retropropagação utilizando técnicas heurísticas e de otimização numérica (descritas no subitem 7.3.1) em dois diferentes gumes: um que apresentou comportamento de desgaste contínuo (gume 14) e outro que apresentou avarias precocemente (gume 7). Segundo a equação 7.6, é necessário tomar pelo menos 12 (doze) amostras de treinamento para 5 (cinco) índices de monitoramento na entrada da rede. Assim, foram considerados os índices de monitoramento extraídos dos resultados dos outros 13 gumes restantes (menos o 7 e o 14), cujos tempos de vida podem ser revistos na figura 8.58.

Para avaliar a generalização, manteve-se o tamanho do conjunto de treinamento fixo e testaram-se diferentes configurações de rede (tabela 8.7). Foram escolhidos 5 índices de monitoramento ( $NF_f$ ,  $NF_p$ ,  $NF_c$ ,  $EA_{RMS}$  e  $VIX_{RMS}$ ) como entradas da RNA para se estimar, numa única saída, o valor de “VB”. Deve-se, portanto, determinar o menor número de neurônios na camada oculta que possa produzir o mapeamento entrada-saída desejado da forma mais suave possível – situação ideal. A escolha das configurações foi baseada na teoria apresentada no item 7.3.1 (Treinamento Supervisionado).




Figura 8.58 – Tempos de vida dos gumes considerados no treinamento da FFBPNN

Tabela 8.7 – Configurações de redes FFNN usadas nos testes

Tipo	Configurações	Iterações
1	5-20-1	1000
2	5-15-1	2000
3	5-12-1	3000
4	5-15-1	10000
5	5-18-1	20000

A tabela 8.8 mostra os resultados alcançados para os gumes 7 e 14. O coeficiente de correlação linear “r” foi determinado a partir da relação entre os valores reais medidos experimentalmente e os valores estimados através da rede neural artificial. A configuração tipo 1 para a rede direta com o algoritmo de treinamento por retropropagação apresentou os melhores resultados em 50% dos casos, seguida pela configuração tipo 3 (30%).

Tabela 8.8 – Melhores resultados dos algoritmos de treinamento para os gumes 7 e 14


Técnica		GUME 7		GUME 14	
		Tipo	Correlação Linear	Tipo	Correlação Linear
Heurística	[train $\mathbf{gdx}$ ]	5	86,9%	1	94,6%
	[train $\mathbf{rp}$ ]	4	88,9%	1	95,3%
Otimização Numérica	[train $\mathbf{cgf}$ ]	1	86,8%	1	94,0%
	[train $\mathbf{bfg}$ ]	1	88,4%	3	92,4%
	[train $\mathbf{lm}$ ]	3	84,3%	3	95,1%

De modo a refinar os resultados, a tabela 8.9 mostra os resultados das técnicas para as configurações tipo 1 e tipo 3. A configuração tipo 1 apresentou um melhor resultado, com uma média global (das correlações lineares) igual a 89,9% contra 88,4% da configuração 3. Desta forma, adotou-se a **rede 5-20-1** com 1000 iterações. Como o melhor resultado da tabela acusa para a técnica heurística de retropropagação flexível [`trainrp`], adotou-se esta técnica para o treinamento por retropropagação da rede direta tipo 1.

**Tabela 8.9** – Melhores resultados dos algoritmos de treinamento para as configurações 1 e 3


Técnica		GUME 7		GUME 14	
		Config 1	Config 3	Config 1	Config 3
Heurística	[ <code>traingdx</code> ]	86,6%	84,6%	94,6%	94,2%
	[ <code>trainrp</code> ]	85,5%	78,6%	95,3%	89,5%
Otimização Numérica	[ <code>traincgf</code> ]	86,8%	84,8%	94,0%	93,7%
	[ <code>trainbfg</code> ]	88,4%	86,6%	89,7%	92,4%
	[ <code>trainlm</code> ]	83,4%	84,3%	94,8%	95,1%

A figura 8.59 ilustra a comparação entre os valores reais da marca de desgaste de flanco para o gume 14 e os valores estimados usando a configuração 5-20-1 com treinamento por retropropagação flexível. Os pontos mostrados indicam os valores ao final de cada passe (apesar da rede fornecer um valor de “ $VB_{est}$ ” por segundo). A linha descontínua representa a tendência dos pontos reais e estimados. Nos 10 minutos iniciais, os comportamentos estimados diferem mais do real que nos 10 minutos finais porque as variáveis de entrada ( $NF_f$ ,  $NF_p$ ,  $NF_c$ ,  $EA_{RMS}$  e  $VI_{RMS}$ ) apresentam pouca variação com as alterações dos valores de desgastes no início da vida da ferramenta. Com isso, pode-se concluir que o sistema é eficaz na determinação dos valores de “VB” quando a ferramenta aproxima-se do seu fim. Assim, o tempo de vida restante pode ser estimado com uma certa confiabilidade.



**Figura 8.59** –Valores estimados de VB do gume 14 usando uma RNA 5-20-1 com treinamento por retropropagação flexível (1000 iterações)


A figura 8.60 ilustra a comparação entre os valores reais da largura da marca de desgaste de flanco para o gume 7 e os valores estimados usando a configuração 5-20-1 com treinamento por retropropagação flexível. A linha descontínua representa a tendência dos pontos reais e estimados. Nota-se que a diferença entre os valores reais e estimados é maior para o gume 7 que para o gume 14, visto que a correlação linear do primeiro é 95,3% e a do segundo é 85,5%. Isto se deve à aleatoriedade do comportamento das falhas, já que os lascamentos começaram a surgir antes do esperado.



**Figura 8.60** –Valores estimados de VB do gume 7 usando uma RNA 5-20-1 com treinamento por retropropagação flexível (1000 iterações)

Com base nos resultados preliminares obtidos no Capítulo 8, o Capítulo 9 mostrará a **Proposta de um Sistema Monitor Inteligente** que terá como incumbência diagnosticar as falhas da ferramenta (a partir da estimativa de valores da largura média da marca de desgaste de flanco e da detecção de avarias) e prognosticar a vida da mesma (a partir da estimativa de “VB”) com a ambição de definir o momento mais apropriado para sua troca.

## 9 - PROPOSTA DE UM SISTEMA MONITOR INTELIGENTE



*“Um sistema TCM inteligente deve ser capaz de **imitar** ao máximo possível as habilidades do ser humano de observar, reconhecer, responder e aprender”.*

(DAVID A. DORNFELD)

O enfoque principal do trabalho está no diagnóstico *on-line* das avarias e desgastes da ferramenta, resultantes de um processo de torneamento longitudinal, partindo das informações coletadas pelos transdutores ao longo do processo. Baseando-se nas informações geradas através do diagnóstico, far-se-á o prognóstico da vida da ferramenta. A escolha das grandezas físicas (força, vibração e emissão acústica) na fusão dos sinais sensórios se justifica pelo fato das informações geradas durante o processo serem complementares.

Pela definição de sistema inteligente de monitoramento discutida no Capítulo 5, a sua concepção envolve basicamente cinco componentes: sensoriamento indireto, condicionamento de sinais, tratamento de sinais e extração de características para o reconhecimento de padrões de falha, processamento paralelo de informações e capacidade de aprendizagem (vide fig. 5.3). A revisão bibliográfica apresentada no trabalho mostrou diversas pesquisas na área de sistemas inteligentes de monitoramento do estado da ferramenta de corte relativas a estes componentes. Uma abordagem geral voltada para o sistema implementado faz-se necessária, identificando os critérios adotados na escolha dos componentes.

### 9.1 Aquisição de Sinais via Múltiplos Sensores

O **sistema sensório indireto *on-line*** (baseado em sinais de força, vibração e emissão acústica) apresenta informações complementares e significativas, visto que podem ser extraídas destes dados relacionados com efeitos microscópicos e macroscópicos na ferramenta de corte para um sistema TCM inteligente.

Os resultados preliminares obtidos no Capítulo 8 puderam mostrar que as componentes da força de usinagem são bastante eficazes no monitoramento da progressão do desgaste de flanco da ferramenta com o tempo de corte – principalmente as de avanço ( $F_r$ ) e passiva ( $F_p$ ) –, mas não são tão sensíveis quanto a assimetria e/ou a curtose da vibração na detecção de trincas e/ou lascamentos da mesma, e vice-versa.

As componentes normalizadas da força de usinagem neutralizam o efeito da variação da velocidade de corte sobre o estado da ferramenta de corte. Como a assimetria e a curtose do sinal de vibração utilizam a média e o desvio-padrão dos pontos captados num certo intervalo de tempo de amostragem, uma variação nos parâmetros de usinagem não altera os resultados – desde que não sejam modificados durante a amostragem. Assim, num sistema de manufatura flexível, em que os parâmetros de usinagem são frequentemente alterados, os índices de monitoramento gerados servirão de base para o diagnóstico *on-line* de falhas na ferramenta, obtido através de um processamento paralelo de informações.

## 9.2 Tratamento de Sinais e Extração de Características

No **tratamento de sinais**, a primeira coisa importante a se fazer é distinguir os sinais estacionários dos não-estacionários, resultantes do processo de torneamento. Os primeiros são contínuos, associados a comportamentos determinísticos e originários regularmente a partir dos desgastes da ferramenta. Os segundos são transitórios, relacionados a comportamentos estocásticos e gerados por trincas progressivas, lascamentos ou quebras.

Os sinais de força tratados no domínio do tempo (raiz média quadrática ou RMS) podem apresentar tanto características contínuas quanto transitórias. Ao longo do desgaste no flanco da ferramenta por abrasão, os padrões de desgastes são relativamente uniformes e os sinais correspondentes apresentam comportamentos determinísticos. Este comportamento é regido por um crescimento continuado da amplitude da parcela estática sem alteração na parcela dinâmica do sinal, além da pouca dispersão dos dados adquiridos com o aumento da largura da marca de desgaste de flanco. Quando a energia (calor) aumenta, os padrões tornam-se irregulares devido aos lascamentos gerados por adesão e trincas térmicas; neste caso, os sinais passam a apresentar comportamentos estocásticos, aumentando abruptamente as amplitudes das parcelas estática e dinâmica, além de um aumento na dispersão dos dados adquiridos de força com o aumento de "VB".

Os sinais de vibração (tensão elétrica  $V_{RMS}$ ) apresentam características similares aos da força – principalmente a de avanço, pois o transdutor está posicionado na direção do eixo X. Para realçar o comportamento não-determinístico do sinal no domínio do tempo, o tratamento estatístico de assimetria e, principalmente, de curtose da distribuição- $\beta$  apresenta-se como uma estratégia eficaz na detecção de avarias em intervalos de tempo reduzidos.

Assim, o sistema deverá efetuar a estimativa de desgaste de flanco até que alguma avaria significativa seja detectada. Se não for, a ferramenta deverá ser trocada, simplesmente porque atingiu a marca de desgaste previamente estabelecida como fim de vida.

### 9.3 Processamento Paralelo de Informações

Um **processamento paralelo de informações** é primordial, onde uma rede neural artificial (RNA) deverá ser gerada para estimar a largura da marca de desgaste de flanco a partir dos índices de monitoramento escolhidos.

Como visto no subitem 7.3.1, uma vez que os índices de monitoramento tenham sido determinados e selecionados, os problemas subseqüentes são: a **representação**, o **aprendizado** e a **generalização**.

A **generalização** apresenta resultados confiáveis para padrões de falha contínuos, em que o lascamento é uma consequência de um desgaste intenso, premeditado e mensurado indiretamente. Já para padrões aleatórios, a detecção de avarias deve funcionar de modo a antecipar a troca da ferramenta por motivo de lascamento e/ou quebra. Neste segundo caso, a rede não se mostrou tão eficaz – como constatado em experimentos preliminares realizados ao longo do trabalho.


### 9.4 Identificação do Estado da Ferramenta

Um **sistema detector** será aplicado no reconhecimento de padrões de avaria com o intuito de identificar a presença de trincas, microlascamentos, lascamentos ou quebra por meio dos valores de assimetria e curtose (índices de monitoramento determinados a partir das características extraídas do sinal de vibração) usados como entrada. O sistema irá trabalhar como um “divisor de águas”: se houver lascamento, a ferramenta alcançou seu fim de vida; senão, o tempo de vida depende do valor de “VB”

Uma **rede neural artificial** será usada no reconhecimento de padrões de desgaste visando estimar o valor de “VB”, considerando cinco índices de monitoramento (obtidos a partir das características extraídas dos sinais de força e vibração) usados como entrada. Nos estudos preliminares, a RNA com topologia direta com 20 neurônios na camada oculta mostrou os melhores resultados na estimativa de valores de VB usando algoritmo de treinamento por retropropagação flexível (RP – *resilient back-propagation*).

## 9.5 Prognóstico do Fim de Vida

A figura 9.1 ilustra a função que relaciona o tempo de vida da ferramenta “ $T_v$ ” com a largura da marca de desgaste de flanco “VB” nas condições de corte mostradas na tabela 8.3. Tomando como referência os quinze gumes utilizados nos ensaios, de 248 medições realizadas, 232 valores de “VB” ficaram dentro da área delimitada pelo gráfico.



**Figura 9.1** – Tempo de vida em função de VB

Baseando-se nos valores estimados de “VB” [mm], um modelo matemático faz um prognóstico do tempo de vida restante da ferramenta “ $T_{res}$ ” [min]. A função que quantifica o tempo “ $T_{res}$ ” é representada pela equação (9.1).

$$T_{res} = T_d \pm R_e$$

onde:  $\left\{ \begin{array}{l} T_d = 20 + 32 \cdot VB - 1578 \cdot VB^2 + 6688 \cdot VB^3 - 8404 \cdot VB^4 \\ R_e = VB^2 \cdot (1020 - 6950 \cdot VB + 11826 \cdot VB^2) \end{array} \right. \quad (9.1)$

A figura 9.2 ilustra o tempo de vida restante da ferramenta “ $T_{res}$ ” em função da largura da marca de desgaste de flanco “VB”. As linhas pontilhadas referem-se à dispersão de



valores de “ $T_{res}$ ” em função de “VB”. Nota-se a maior dispersão para valores próximos de 0,15 mm, mostrando de uma forma diferente a variação observada na figura 8.25.




Figura 9.2 – Tempo de vida restante em função de VB

Para um prognóstico de tempo de vida entre  $(19,4 \pm 1,5)$  min e  $(4,0 \pm 4,6)$  min, a derivada da função pode ser representada por uma reta. Isto mostra que um tempo acima que 19,4 min sinaliza a região primária de desgaste ou **inicial**, onde ocorre a estabilização do gume. Um tempo abaixo de 4,0 min indica a região terciária de desgaste ou **catastrófica**. O intervalo entre 19,4 min e 4,0 min de tempo restante representa a região secundária de desgaste ou **normal**. Portanto, a ferramenta merecerá atenção redobrada quando o tempo restante aproximar-se de 4 minutos – isto se não ocorrer nenhuma avaria comprometedora no período decorrido de 16 minutos de vida.

A figuras 9.3 e 9.4 mostram respectivamente a relação entre os valores reais e os estimados do tempo de vida restante para os gumes 7 e 14 (item 8.5) em função da largura da marca de desgaste de flanco (VB) sem a atuação do sistema detector de avarias.





Figura 9.3 – Relação entre os tempos reais e estimados do tempo de vida restante ao gume 7

Para o gume 7, a correlação entre os valores reais e os estimados (tendência) foi de 97,7%. Pode-se observar que apenas o primeiro ponto (16,4 min) não está incluído no intervalo delimitado pela repetitividade.




**Figura 9.4** – Relação entre os tempos reais e estimados do tempo de vida restante ao gume 14

Para o gume 14, a correlação entre os valores reais e os estimados (tendência) foi de 98,6%. Neste, todos os pontos estão incluídos no intervalo delimitado pela repetitividade.

Após a proposta feita no Capítulo 9, vem a etapa de **Implementação do Sistema Monitor** no Capítulo 10 que inclui, além da arquitetura do sistema, os devidos testes de aplicação em três diferentes gumes. Comentários, **Conclusões e Perspectivas** serão apresentados no Capítulo 11.

## 10 - IMPLEMENTAÇÃO DO SISTEMA MONITOR



*“A implementação bem sucedida de um sistema TCM inteligente depende de dois fatores: (a) da qualidade das informações coletadas pelos sensores; e (b) do algoritmo de inteligência computacional usado para analisar as características extraídas dos dados sensórios e tomar as devidas decisões”.*

Kang-Ning Lou e Cheng-Jen Lin

Tomando como base os experimentos realizados em 15 gumes, em que se puderam avaliar as características extraídas dos cinco sinais sensórios (três componentes da força de usinagem, vibração e emissão acústica), a próxima fase do trabalho consiste (a) na estimativa dos valores quantitativos de desgastes, (b) na detecção de avarias e (c) na estimativa do tempo de vida restante para a ferramenta de corte.

### 10.1 Arquitetura do Sistema

O **Sistema Monitor** implementado pode ser esquematizado a partir do diagrama de blocos da figura 10.1.

Os sinais sensórios provenientes dos transdutores piezelétricos (KISTLER<sup>®</sup> 9257-A; PROMETEC<sup>®</sup> AE-30 e SENSIS<sup>®</sup> EA) são devidamente condicionados (KISTLER<sup>®</sup> 5011; PROMETEC<sup>®</sup> AE-GDV e SENSIS<sup>®</sup> BM-12). Os sinais de vibração ( $VI_x$ ) e emissão acústica (EA) passam também por filtragem digital via MATLAB<sup>®</sup>, de modo a assegurar as características dos sinais dentro das faixas de frequências delimitadas pelo AE-GDV e pelo BM-12.

Os sinais condicionados passam em seguida para a etapa de processamento – determinação dos **índices de monitoramento** –, onde: as componentes ortogonais da força de usinagem (avanço “Ff”, passiva “Fp” e corte “Fc”) são normalizadas (equações 6.2 a 6.4); os sinais de vibração são amostrados num intervalo de tempo de 16 ms para se poder obter a raiz média quadrática (equação 5.3) e a variância (equação 5.2), resultados estes que se-

rão aplicados na determinação da assimetria (equação 5.9) e da curtose (equação 5.10); os sinais de emissão acústica são processados como os de vibração.

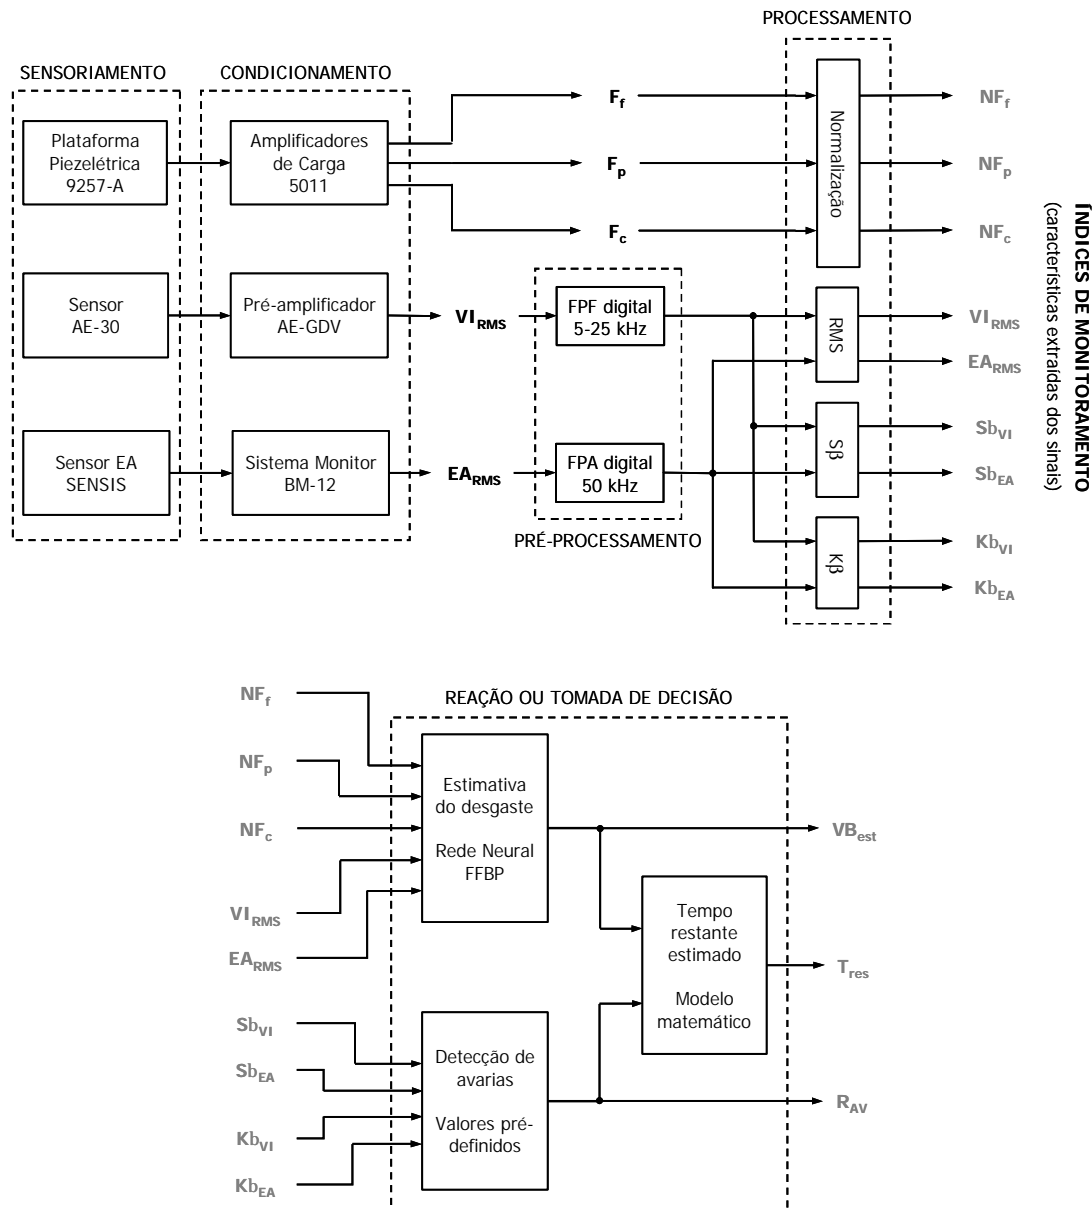



Figura 10.1 – Arquitetura do Sistema Monitor

Após a determinação dos índices de monitoramento, a etapa posterior consiste na **estimativa** dos valores quantitativos da largura da marca de desgaste de flanco ( $VB_{est}$ ) e a **deteção** de avarias ( $R_{AV}$ ) da ferramenta. A estimativa usa uma rede neural direta 5-20-1 com algoritmo de treinamento por retropropagação flexível. O treinamento da rede foi baseado nas informações extraídas dos ensaios com os 15 gumes (item 8.2.2).

A detecção é realizada a partir de um algoritmo lógico que compara a intensidade de avaria detectada por assimetria e curtose com os valores previamente definidos no item 8.4.2. Com base nos resultados de estimativa e detecção, um modelo matemático (equação 9.1) calcula o tempo restante.

## 10.2 Aplicação do Sistema

De modo a verificar o funcionamento e o desempenho do sistema monitor, foram realizados ensaios de fim de vida de três gumes (A, B e C), cujos valores de desgaste podem ser vistos na figura 10.1.



**Figura 10.1** – Curva de vida das ferramentas A, B e C

Os critérios de fim de vida seguiram os mesmos procedimentos do item 8.2.2. Os parâmetros de corte adotados foram os mesmos apresentados na tabela 8.3.

Os dados de monitoramento foram adquiridos simultaneamente ao processo com base nas configurações testadas no Capítulo 8 e fundamentadas no Capítulo 9, com a diferença no tempo de aquisição: o sistema foi programado para calcular o tempo efetivo de corte em cada passe com base no diâmetro e no comprimento usinado do corpo de prova<sup>45</sup>.

<sup>45</sup> A diferença do tempo do primeiro para o último passe ocorre por causa das condições de corte. Como a velocidade de corte ( $v_c$ ), o avanço por rotação ( $f$ ) e o comprimento usinado ( $L$ ) são constantes, o tempo de percurso ( $t$ ) diminui com a diminuição do diâmetro da peça ( $D$ ), segundo a equação:


$$t = \frac{\pi \cdot D \cdot L}{1000 \cdot f \cdot v_c}$$

Tendo como referência o diâmetro inicial “ $D_0$ ” e o comprimento inicial “ $L_0$ ”, o tempo “ $t$ ” foi determinado pela equação 10.1, onde “ $P$ ” é o número do passe em cada corpo de prova (lembrando que cada corpo de prova sofreu 16 passes):


$$t [s] = \frac{3 \cdot \pi \cdot (D_0 - 2 \cdot P \cdot a_p) \cdot (L_0 - P\sqrt{3})}{50 \cdot v_c \cdot f} \quad (10.1)$$

Para o primeiro corpo de prova, “ $P$ ” =  $P_1$ , e para o segundo, “ $P$ ” =  $(P_2 - 16)$ , onde  $P_1$  e  $P_2$  são os números dos passes nos corpos de prova:  $P_1 = 1 \sim 16$ ;  $P_2 = 17 \sim 32$ . Exemplificando, o tempo de corte (tempo de aquisição) do passe  $P = 12$  ( $P_1 = 12$  ou  $P_2 = 28$ ) para um corpo de prova (1 ou 2) com  $D_0 = 98$  mm e  $L_0 = 310$  mm é de **32 segundos**.

Os gumes A e C apresentaram lascamento após 17 min. Os valores médios medidos antes do lascamento foram respectivamente 200 e 233  $\mu\text{m}$ . Para o gume B, o lascamento surgiu após 18min e  $VB = 182$   $\mu\text{m}$ . As figuras 10.2 e 10.3 mostram as fotos dos gumes tiradas nos tempos de vida especificados.



**Figura 10.2** – Fotos dos gumes A, B e C anteriormente ao lascamento (desgaste avançado)



**Figura 10.3** – Fotos dos gumes A, B e C lascados

A verificação será efetuada em três partes distintas. Primeiramente será mostrado como o sistema efetuou a detecção de avarias na ferramenta para cada um dos três gumes. Em seguida, a estimativa do valor da largura da marca de desgaste de flanco. Por fim, a determinação do tempo de vida restante da ferramenta.

### 10.2.1 Detecção de Avarias

#### (a) Gume A

As figuras 10.4 e 10.5 mostram o instante em que a avaria (lascamento) foi detectada durante o passe 25 (entre 17,0 e 17,6 min de vida).




Figura 10.4 – Detecção da fratura do gume A: força e emissão acústica




Figura 10.5 – Detecção da fratura do gume A: vibração

A assimetria ( $S_{\beta}$ ) e a curtose ( $K_{\beta}$ ) da distribuição- $\beta$  do sinal de vibração tomado no domínio do tempo evidenciaram o escalonamento dos valores das forças normalizadas no

mesmo instante. Para este gume, o sinal de EA evidenciou a fratura somente através da curtose – mesmo assim, com muito menos amplitude que  $VI_x$ . O lascamento ocorreu aos 17 min 12 seg ( $81 \pm 20$ ) ms.

### (b) Gume B

As figuras 10.6 e 10.7 mostram o instante em que a avaria (lascamento) foi detectada durante o passe 27 (entre 18,2 e 18,7 min de vida). A assimetria ( $S_\beta$ ) e a curtose ( $K_\beta$ ) da distribuição- $\beta$  do sinal de vibração, tomado no domínio do tempo, tornaram evidente o que não se pôde observar pelos valores das forças normalizadas no mesmo instante. Para este gume, tanto a assimetria quanto a curtose do sinal de emissão acústica não apresentaram qualquer alteração significativa que pudesse inferir sobre a presença ou não de fratura. O lascamento ocorreu aos 18 min 26 seg ( $852 \pm 20$ ) ms.




Figura 10.6 – Detecção da fratura do gume B: componentes normalizadas da força de usinagem

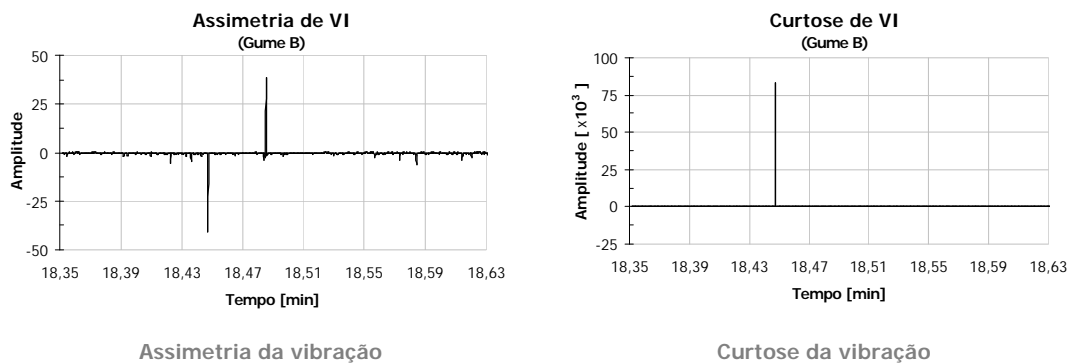



Figura 10.7 – Detecção da fratura do gume B: vibração




## (c) Gume C


As figuras 10.8, 10.9 e 10.10 mostram o instante em que a avaria (lascamento) foi detectada durante o passe 25 (entre 17,0 e 17,6 min de vida).



**Figura 10.8** – Detecção da fratura do gume B: componentes normalizadas da força de usinagem



**Figura 10.9** – Detecção da fratura do gume C: vibração



**Figura 10.10** – Detecção da fratura do gume C: emissão acústica

A assimetria ( $S_\beta$ ) e a curtose ( $K_\beta$ ) da distribuição- $\beta$  do sinal de vibração tomadas no domínio do tempo evidenciaram o quase imperceptível escalonamento dos valores das forças normalizadas no mesmo instante.


Para este gume, o sinal de emissão acústica evidenciou a fratura através da assimetria e da curtose antes da vibração. O primeiro sinal de que houve lascamento, detectado pela emissão acústica (tomado como referência no tempo de vida restante), ocorreu aos 17 min 20 seg ( $940 \pm 20$ ) ms. Pela vibração (e pelas forças normalizadas), o lascamento só aconteceu aos 17 min 24 seg ( $460 \pm 20$ ) ms.

Para o **gume C**, pôde-se perceber que a emissão acústica apresentou-se mais sensível ao lascamento, principalmente quando o desgaste de flanco já se encontrava em estágio avançado (possivelmente por causa do comportamento dinâmico do sinal). No **gume B**, como o desgaste de flanco não ultrapassou 200  $\mu\text{m}$ , a EA não acusou a presença de lascamento. Em relação ao **gume A**, apenas a curtose da distribuição- $\beta$  do sinal de EA pôde detectar, mas ainda assim numa amplitude bem menos evidente que a vibração.

### 10.2.2 Estimativa da Marca de Desgaste de Flanco

#### (a) Gume A

A figura 10.11 mostra os valores medidos (reais) e estimados para a largura média da marca de desgaste de flanco para o gume A. O coeficiente de correlação linear entre os valores reais e estimados ficou em 97,7%, mostrando que os resultados foram bastante satisfatórios. A capacidade de generalização da rede mostrou resultados excelentes, mesmo no início da vida da ferramenta. A tabela A.2 (Anexo A4) expõe esses valores.



**Figura 10.11** – Comparação entre os valores estimados e reais de VB para o gume A

### (b) Gume B

A figura 10.12 mostra os valores medidos (reais) e estimados para a largura média da marca de desgaste de flanco para o gume B. A correlação linear entre os valores estimados e reais ficou em 94%, mostrando que os resultados ficaram dentro do esperado – apesar das dispersões entre 4 e 10 min e após os 16 minutos do tempo de vida da ferramenta. A tabela A.3 (Anexo A4) apresenta os valores obtidos.




Figura 10.12 – Comparação entre os valores estimados e reais de VB para o gume B

### (c) Gume C

A figura 10.13 mostra os valores medidos (reais) e estimados para a largura média da marca de desgaste de flanco para o gume C. O coeficiente de correlação linear entre os valores reais e estimados ficou em 96%, mostrando que o sistema atingiu bem seu objetivo em estimar os valores de “VB”. A tabela A.4 (Anexo A4) exhibe esses valores.




Figura 10.13 – Comparação entre os valores estimados e reais de VB para o gume C

No gume C, a maior dispersão ocorreu no início do tempo de vida da ferramenta – mais comum e mais esperado, devido à baixa variação da amplitude dos sinais monitorados (e conseqüentemente dos índices de monitoramento) com o gradiente de desgaste inicial.

### 10.2.3 Tempo Restante Estimado

#### (a) Gume A

A figura 10.14 mostra o tempo restante estimado para o gume A. O sistema consegue prognosticar o fim de vida da ferramenta dentro de uma margem de erro relativamente grande, mas confiável. Observa-se que quando o tempo mínimo atingiu " $T_{res}$ " = 0, o gume A dispunha somente de 36 segundos de vida, ou seja, o seu último passe. Assim, o fim de vida foi determinado pelo Sistema Monitor antes que se iniciasse o passe 25, no qual ocorreu o lascamento.




Figura 10.14 – Tempo de vida restante para o gume A





Figura 10.15 – Indicação do fim de vida do gume A pelo sistema monitor

Ao final do passe 25, o valor estimado do de desgaste de flanco foi 222  $\mu\text{m}$  mas, no momento do lascamento ( $T_v = 17,2$  min), o tempo de vida restante passou a ser zero, como mostra a figura 10.15. A tabela A.2 (Anexo A4) mostra os resultados obtidos.


### (b) Gume B

A figura 10.16 mostra o tempo restante estimado para o gume B. Novamente, o sistema consegue prognosticar o fim de vida da ferramenta dentro de uma margem de erro grande e confiável.



**Figura 10.16** – Tempo de vida restante para o gume B

Quando o tempo mínimo atingiu " $T_{res} = 0$ " (ao final do passe 23 com  $VB = 168 \mu\text{m}$ ), o gume B dispunha de 2,3 minutos de vida. A partir deste passe até o lascamento (ao longo do passe 27), a atenção foi redobrada. Ao final do passe 27, o valor estimado do desgaste de flanco foi 260  $\mu\text{m}$  mas, no momento do lascamento ( $T_v = 18,44$  min), o tempo de vida restante passou a ser zero, como mostra a figura 10.17. Resultados no Anexo A4.



**Figura 10.17** – Indicação do fim de vida do gume B pelo sistema monitor

## (c) Gume C

A figura 10.18 mostra o tempo restante estimado para o gume C. Como nos casos anteriores, o prognóstico do fim de vida ocorre dentro de uma margem de erro bastante confiável.




Figura 10.18 – Tempo de vida restante para o gume C

Quando o tempo mínimo atingiu " $T_{res} = 0$ " (ao final do passe 16 com  $VB = 182 \mu\text{m}$ ), o gume C dispunha de 6,7 minutos de vida. A partir deste passe, a atenção foi redobrada. O lascamento aconteceu ao longo do passe 25; ao final deste passe, o valor estimado do desgaste de flanco foi  $237 \mu\text{m}$  mas, no momento do lascamento ( $T_v = 17,35 \text{ min}$ ), o tempo de vida restante passou a ser zero, como mostra a figura 10.19. A tabela A.4 (Anexo A4) mostra os resultados obtidos.





Figura 10.19 – Indicação do fim de vida do gume C pelo sistema monitor

# 11 - CONCLUSÕES E PERSPECTIVAS



*“A realidade e a promessa ainda não se encontraram. Muita coisa já foi feita, mas ainda há muito por fazer. A quantidade de esforços dedicados à tecnologia de sensoriamento para aplicações em ambiente industrial oferece evidências de que muitas promessas feitas há tempos darão frutos. Desta perspectiva antevê-se que a realidade e a promessa vão se misturar cada vez mais nos próximos anos”.*

DAVID WELLS

## 11.1 Capacidade do Sistema

Baseando-se nas técnicas de aquisição e processamento de sinais de força, vibração e emissão acústica (Capítulos 5 e 6), e na aplicação de redes neurais artificiais em processos de usinagem (Capítulos 5 e 7), este trabalho apresentou as etapas de desenvolvimento (Capítulos 8 e 9) e implementação (Capítulos 9 e 10) de um **Sistema Monitor Inteligente** capaz de supervisionar e diagnosticar o estado da ferramenta de corte em metais ao longo de sua vida num torno CNC com a mínima participação humana.

A integração de múltiplos sinais (devidamente condicionados e tratados) foi feita através de uma rede neural artificial direta 5-20-1 com algoritmo de treinamento por retropropagação flexível implementada via MATLAB<sup>®</sup>. Esta configuração foi determinada após uma série de testes combinando diferentes: número de neurônios na camada oculta; técnicas de aprendizado; e ciclos de treinamento (item 8.5).

O **Sistema Monitor** completo atua em três funções: (a) estima o valor da largura da marca de desgaste de flanco (VB); (b) detecta o momento que ocorre a fratura (lascamentos e/ou quebra); (c) efetua o prognóstico do tempo de vida restante da ferramenta. Ao efetuar os testes com três gumes diferentes (A, B e C) – Capítulo 10, foi possível verificar o desempenho destas três funções.

### 11.1.1 Estimativa dos Valores de VB

Pela distinção entre **eficiência** e **eficácia** de CHIAVENATO<sup>46</sup>[196], a “eficiência” reside basicamente em fazer as coisas da melhor maneira possível (resolver problemas) e “eficácia” em fazer as coisas que são importantes para os resultados (alcançar o objetivo).

Apesar de ter-se buscado também a “eficiência” do Sistema Monitor nesta função, pode-se dizer que a estimativa da largura média da marca de desgaste de flanco obtida através da rede neural artificial direta 5-20-1 com algoritmo de treinamento por retropropagação flexível (1000 iterações) foi “eficaz”, visto que a correlação linear entre os valores reais medidos e os estimados ficou entre 94% (Gume B) e 97,7% (Gume A).

### 11.1.2 Detecção de avarias

Para os Gumes A e B, a assimetria e a curtose do sinal de vibração mostrou-se “eficiente” e “eficaz” na detecção do lascamento. Ele ocorreu aos 17 min 12 seg ( $81 \pm 20$ ) ms para o Gume A e aos 18 min 26 seg ( $852 \pm 20$ ) ms para o Gume B. A emissão acústica não evidenciou a presença da avaria de forma significativa.

Já para o Gume C, enquanto o sinal de vibração acusava a ocorrência do lascamento via assimetria e curtose aos 17 min 24 seg ( $460 \pm 20$ ) ms, a emissão acústica já havia detectado aos 17 min 20 seg ( $940 \pm 20$ ) ms, ou seja, pouco menos de 4 segundos antes. Neste caso, a vibração mostrou-se mais “eficiente” e a emissão acústica, mais “eficaz”.

A situação de detecção de avarias dos três gumes apresentados reflete bem a importância da aplicação de multisensores, pois a ausência de um índice de monitoramento pode ser compensada pela presença de outro. Desta forma, esta função no sistema monitor pode ser considerada “eficiente” e “eficaz” dentro das suas capacidades e limitações.

### 11.1.3 Prognóstico da vida da ferramenta

O cálculo do tempo de vida restante baseou-se na tendência e na repetitividade dos resultados experimentais obtidos a partir do ensaio de fim de vida de 15 gumes. Com isso, a equação (9.1) mostra os valores máximo e mínimo do tempo de vida estimados.

---

<sup>46</sup> Idalberto Chiavenato é doutor em administração de empresas pela City University of Los Angeles e autor de mais de 30 obras na área de administração.



Para o Gume A, o fim de vida a partir do valor mínimo foi estimado 1 (um) passe antes do qual ocorreria o lascamento. Para o Gume B, o prognóstico foi mais grosseiro: 4 (quatro) passes antes. Para o Gume C, foi ainda pior: 9 (nove) passes antes. Esta função do Sistema Monitor mostrou-se, portanto, “eficiente”, mas um pouco longe de atingir seu objetivo de determinar o momento mais apropriado para a troca.

Pode-se então chegar à conclusão que a função do Sistema Monitor de prognosticar a vida da ferramenta é estimar de maneira grosseira o tempo de vida restante – devido à grande repetitividade. A partir desta estimativa, pode-se saber que a ferramenta está relativamente próxima do seu fim de vida.

Incorporando a detecção de avarias (uma função “eficaz” do sistema) a essa função, o tempo de vida restante cai abruptamente para zero quando uma avaria é detectada, tornando o sistema capaz de “prever” que o fim de vida está próximo e quando ele acontece. Vale lembrar que se não houvesse detecção de avarias, o fim de vida seria decretado quando o valor médio (tendência) do tempo restante estimado chegasse a zero. Nos três casos (Gumes A, B e C), houve a detecção.

## 11.2 Limitações

- ☑ O Sistema Monitor atuou em condições únicas de usinagem (tabela 8.3), limitando a aplicação para uma única ferramenta de corte para remover material de um mesmo tipo de corpo de prova. Não foi avaliada a variação dos parâmetros.
- ☑ Faltou explorar mais os índices de monitoramento que podem ser extraídos dos sinais de emissão acústica, tanto no domínio do tempo quanto no domínio da frequência (ou em ambos, como na transformada da *Wavelet*).
- ☑ A abordagem de colisão foi apresentada no Capítulo 4 e não foi devidamente analisada no trabalho. Sabe-se, porém, que a estratégia assemelha-se bastante com o sistema de detecção de avarias.

## 11.3 Tendências e Direções

- ☑ A integração de sensores em grande escala é vista como um ponto-chave para a aplicação da inteligência artificial ao controle da manufatura em tempo real. Mesmo que as RNA's sejam só um tópico para o processamento dos sinais sensórios num ambiente de

RNA's sejam só um tópico para o processamento dos sinais sensórios num ambiente de controle, elas têm um vasto potencial de impacto nas estratégias de monitoramento em projeto, programação e operação de células inteligentes de manufatura.


- ☑ Os estudos mais recentes sobre sistemas de monitoramento de máquinas, ferramentas e processos visam desenvolver: (a) critérios mais confiáveis para monitorar o desgaste da ferramenta em tempo real; (b) técnicas para previsão e detecção rápida de desgastes e avarias nas ferramentas de corte; (c) estratégias de processamento mais velozes para supervisionar operações de usinagem de alta precisão; (d) novos sensores com maiores potencialidades e menores custos para implantação em chão-de-fábrica.
- ☑ As empresas brasileiras, aos poucos, estão investindo na tecnologia de monitoramento e automação buscando minimizar os custos intrínsecos ao processo de usinagem, principalmente no que se refere à determinação do melhor momento para a substituição de ferramentas (redução de desperdício de ferramental e do refugo de peças) e a minimização do efeito da colisão da ferramenta contra a peça ou contra a placa da máquina-ferramenta.

## 11.4 Propostas para Trabalhos Futuros

- ☑ Um sistema de detecção de contato baseado em um microcontrolador e no sensor piezelétrico de vibração (ou emissão acústica) que possibilite a minimização do efeito da colisão com a movimentação errônea da ferramenta. Um sinal de pico de alta amplitude serviria como entrada do dispositivo que registraria o contato (sinal acima de um valor pré-determinado) e promoveria a interrupção da movimentação do carro e do giro da placa da máquina-ferramenta.
- ☑ Com a capacidade de aprendizagem, um sistema TCM inteligente poderia adaptar-se às diferentes condições de usinagem em sistemas de manufatura integrados e flexíveis, já que como visto no Capítulo 2, diversos fatores influenciam direta ou indiretamente no tempo de vida de uma ferramenta. Considerando a velocidade de corte ( $v_c$ ), o avanço ( $f$ ) e a profundidade de corte ( $a_p$ ) como entradas adicionais das redes neurais artificiais (RNA), ter-se-ão relativas alterações nos resultados diagnosticados.
- ☑ A aplicação da transformada de *wavelet* no processamento dos sinais de força, vibração e emissão acústica para a obtenção dos índices de monitoramento. Posteriormente, a implementação e o teste da rede neural artificial.

- ☑ Uma outra possibilidade seria a aplicação de RNA's não-supervisionadas tipo ART-2, as quais possuem habilidades excelentes como [65]: alta velocidade de aprendizagem (em tempo real) sem a necessidade de grande amostragem, adaptação às alterações do meio, capacidade de preservar os conhecimentos adquiridos anteriormente e aptidão para auto-organizar as entradas seqüenciais arbitrárias.
- ☑ A verificação de desempenho na comparação entre os algoritmos de inteligência computacional (redes neurais artificiais, lógica nebulosa, sistemas neuro-nebulosos) nas aplicações em chão-de-fábrica.
- ☑ A implementação do sistema em operações de fresamento e/ou furação, por exemplo.

## REFERÊNCIAS



- 1 LOU, K.-N.; LIN, C. -J. (1997). An intelligent sensor fusion system for tool monitoring on a machine centre. *The International Journal of Advanced Manufacturing Technology*, v.13, p.556-565
- 2 KLUFT, W. (2003). Sistema de monitoramento modular: Promos II (PROMETEC GmbH-Aachen). Apresentado pelo Prof. Dr.-Ing Walter Lindolfo Weingaertner no *II Congresso Brasileiro de Engenharia de Fabricação*, Uberlândia – MG, maio.
- 3 VARMA, A. H.; KLINE, W. A. (1990). Force transducer applications on CNC lathes. Presented at *III Advanced Machining Technology Conference*, 4-6 Sept, Society of Manufacturing Engineers.
- 4 MICHELETTI, G. F.; KÖNIG, W.; VICTOR, H. R. (1976). In-process tool wear sensors for cutting operations. Key-Note-Paper C. *Annals of the CIRP*, v.25, n.2, p.483-496.
- 5 TLUSTY, J.; ANDREWS, G. C. (1983). A critical review of sensors for unmanned machining. Key-Note-Papers. *Annals of the CIRP*, v.32, n.2, p.563-572.
- 6 MORIWAKI, T. (1984). Sensing and prediction of cutting tool failure. *Bulletin of the Japan Society of Precision Engineering*, v.18, n.2, p.90-96
- 7 BLUM, T.; SUZUKI, I.; INASAKI, I. (1988). Development of a condition monitoring system for cutting tools using an acoustic emission sensor. *Bulletin of the Japan Society of Precision Engineering*, v.22, n.4, p.301-308
- 8 DAN, L.; MATHEW, J. (1990). Tool wear and failure monitoring techniques for turning – a review. *International Journal of Machine Tools and Manufacturing*, v.30, n.4, p.579-598.

- 9 BYRNE, G. *et al.* (1995). Tool condition monitoring – the status of research and industrial application. Keynote Papers. *Annals of the CIRP*, v.44, n.2, p.541-567.
- 10 KURADA, S.; BRADLEY, C. (1997). A review of machine vision sensors for tool condition monitoring. *ELSEVIER Computers in Industry*, v.34, p.55-72.
- 11 DIMLA, D. E. (2000). Sensor signals for tool-wear monitoring in metal cutting operations – a review of methods. *International Journal of Machine Tools and Manufacturing*, v.40, n.8, p.1073-1098.
- 12 SICK, B. (2002). On-line and indirect wear monitoring in turning with artificial neural networks: a review of more than a decade of research. *Mechanical Systems and Signal Processing*, v.16, n.4, p.487-546.
- 13 JEMIELNIAK, K. (1999). Commercial tool condition monitoring systems. *The International Journal of Advanced Manufacturing Technology*, v.15, n.10, p.711-721.
- 14 DORNFELD, D. A. (1990). Neural network sensor fusion for tool condition monitoring. *Annals of the CIRP*, v.39, n.1, p.101-105.
- 15 RANGWALA, S.; DORNFELD, D. (1990). Sensor integration using neural networks for intelligent tool condition monitoring. *ASME Journal of Engineering for Industry*, v.112, n.3, p.219-228.
- 16 CHILDS, T. H. C. *et al.* (2000). *Metal machining – theory and applications*. London: Butterworth-Heinemann, 406p.
- 17 MICHELETTI (1986). *Mecanizado por arranque de viruta*. 1.ed. Barcelona: Blume, 426p.
- 18 TRENT, E. M.; WRIGHT, P. K. (2000). *Metal cutting*. 4.ed. Boston: Butterworth-Heinemann, 446p.
- 19 KÖNIG, W., KLOCKE, F. (1997). *Fertigungsverfahren – Drehen, Fräsen, Bohren*. 5.ed., Berlin: Springer-Verlag, 417p.
- 20 MACHADO, A. R.; SILVA, M. B. (1999). *Usinagem dos metais*. 4.ed. Laboratório de Ensino e Pesquisa em Usinagem – UFU, Uberlândia./apostila/ 214p.
- 21 STEMMER, C. E. (1995). *Ferramentas de corte I*. 4.ed., Florianópolis: Editora da UFSC, 249p.

- 22 DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. (2001). *Tecnologia da usinagem dos materiais*. 3.ed. São Paulo: Artliber Editora, 244p.
- 23 ZHOU, Q.; HONG, G. S.; RAHMAN, M. (1995). A new tool life criterion for tool condition monitoring using a neural network. Contributed Paper. *Engineering Application of Artificial Intelligence*, v.8, n.5, p.579-588.
- 24 DAS, S.; BANDYOPADHYAY, P. P.; CHATTOPADHYAY, A. B. (1997). Neural networks-based tool wear monitoring in turning medium carbon steel using a coated carbide tool. *Journal of Materials Processing Technology*, v.63, n.1-3, p.187-192.
- 25 QUAN, Y.; ZHOU, M.; LUO, Z. (1998). On-line robust identification of tool-wear via multi-sensor neural-network fusion. Contributed Paper. *Engineering Applications of Artificial Intelligence*, v.11, n.6, p.717-722.
- 26 LI, X.; DONG, S.; VENUVINOD, P. K. (2000). Hybrid learning for tool-wear monitoring. *The International Journal of Advanced Manufacturing Technology*, v.16, n.5, p.303-307.
- 27 MONOSTORI, L.; PROHASZKA, J. (1993). A step towards intelligent manufacturing: modelling and monitoring of manufacturing processes through artificial neural networks. *Annals of the CIRP*, v.42, n.1, p.485-488.
- 28 LEEM, C. S.; DORNFELD, D. A.; DREYFUS, S. E. (1995). A customized neural network for sensor fusion in on-line monitoring of cutting tool wear. *ASME Journal of Engineering for Industry*, v.117, n.2, p.152-159.
- 29 NIU, Y. M.; WONG, Y. S.; HONG, G. S. (1998). An intelligent sensor system approach for reliable tool flank wear recognition. *The International Journal of Advanced Manufacturing Technology*, v.14, n.2. p.77-84
- 30 BLACK, J. T. (1998). *O projeto da fábrica com futuro*. Porto Alegre: Bookman Companhia, 288p.
- 31 FERRARESI, D. (1977). *Fundamentos da usinagem dos metais*. São Paulo: Edgard Blücher, 796p.
- 32 KALPAKJIAN, S. (1995). *Manufacturing engineering and technology*. 3.ed., Reading: Addison-Wesley Publishing Company, 1296p.

- 33 BLACK, J. T. (1994). *Introduction to machining processes*. In: METALS HANDBOOK. Vol. 16: *Machining*. 9.ed. Washington: ASM International, p.1-4.
- 34 BRALLA, J. G. (1986). *Handbook of product design for manufacturing: a practical guide to low-cost production*. New York: McGraw-Hill Book Company, 1138p.
- 35 KOELSCH, J. R. (2000). Ferramentas de carbetos: o estado da arte. *Máquinas e Metais*, v.36, n.415, p.186-201.
- 36 TEIXEIRA, C. R. (2001). *Redução e eliminação de fluidos de corte nos processos de usinagem com ferramentas de geometria definida*. Florianópolis, 157p. Tese (Doutorado) – POSMEC, UFSC.
- 37 SHAW, M. C. (1989). *Metal cutting principles*. New York: Oxford University Press, 616p.
- 38 MESQUITA, N. G. M. (1992). *Avaliação e escolha de uma superfície segundo sua função e fabricação*. Florianópolis, 142p. Tese (Doutorado) – POSMEC, UFSC.
- 39 RISBOOD, K. A.; DIXIT, U. S.; SAHASRABUDHE, A. D. (2003). Prediction of surface roughness and dimensional deviation by measuring cutting forces and vibrations in turning process. *Journal of Materials Processing Technology*, v.132, n.1-3, p.203-214.
- 40 INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (1993). ISO 3685: *Tool-life testing with single-point turning tools*. 2.ed. Genève, 48p.
- 41 DIEI, E. N.; DORNFIELD, D. A. (1987). A model of tool fracture generated acoustic emission during cutting. *ASME Journal of Engineering for Industry*, v.109, n.3, p.234-240.
- 42 WEINGAERTNER, W. L.; SOUZA, A. J. (2002). Aplicação de um sistema de monitoramento inteligente no diagnóstico de falhas em ferramentas de corte: uma abordagem teórica. *II Congresso Nacional de Engenharia Mecânica*. João Pessoa, PB, 10p.
- 43 UEHARA, K.; TAKESHITA, H. (1989). Prognostication of the chipping of cutting tools. *Annals of the CIRP*, v.38, n.1, p.95-98.
- 44 COLGAN, J. et al. (1994). On-line tool breakage detection in turning: a multi-sensor method. *ASME Journal of Engineering for Industry*, v.116, n.1, p.117-123.
- 45 JEMIELNIAK, K. (1992). Detection of cutting-edge breakage in turning. *Annals of the CIRP*, v.41, n.1, p.97-100.

- 46 WELLS, D. (1993). Tecnologia de supervisão para sistemas flexíveis de manufatura. *Revista Máquinas e Metais*, v.27, n.325, p.48-64.
- 47 SOUZA, A. J. (1999). Desenvolvimento e implementação de funções de automação inteligentes num torno CNC utilizando técnicas de monitoramento por emissão acústica. São Carlos. 82p. Dissertação (Mestrado) – EESC, USP.
- 48 IMS-SIMON (2002). *Intelligent manufacturing systems. Sensor fused intelligent monitoring system for machining*. Generic concept. /homepage/  
<http://www.wzl.rwth-aachen.de/WM/IMS-SIMON/main.html>
- 49 BARRON, R. (1996). *Engineering condition monitoring: practice methods and applications*. Harlow: Addison-Wesley, 239p.
- 50 TONSHOFF, H. K. *et al.* (1988). Developments and trends in monitoring and control of machining processes. Keynote Paper. *Annals of the CIRP*, v.37, n.2, p.611-622.
- 51 BUKKAPATNAM, S. T. S.; LAKHTAKIA, A.; KUMARA, S. R. T. (1997). Chaotic neurons for on-line quality control in manufacturing. *The International Journal of Advanced Manufacturing Technology*, v.13, n.2, p.95-100.
- 52 GHASEMPOOR, A.; JESWIET, J.; MOORE, T. N. (1999). Real time implementation of on-line tool condition monitoring in turning. *International Journal of Machine Tools and Manufacture*, v.39, n.12, p.1883-1902.
- 53 CHOUDHURY, S. K.; JAIN, V. K.; RAMA KRISHNA, S. (2001). On-line monitoring of tool wear and control of dimensional inaccuracy in turning. *ASME Journal of Manufacturing Science and Engineering*, v.123, n.1, p.10-12.
- 54 TAYLOR, H. R. (1997). *Data acquisition for sensor systems*. London: Chapman & Hall, 327p.
- 55 WILD, P. (1994) *Industrial sensors and applications for condition monitoring*. London: Mechanical Engineering Publications Ltd., 127p.
- 56 PEDERSEN, K. B. (1990). Wear measurement of cutting tools by computer vision. *International Journal of Machine Tools and Manufacture*, v.30, n.1, p.131-139.
- 57 TESHIMA, T.; SHIBASAKA, T. (1993). Estimation of cutting tool life by processing tool image data with neural network. *Annals of the CIRP*, v.42, n.1, p.59-62.



- 58 KWON, Y.; FISCHER, G. W. (2003). A novel approach to quantifying tool wear and tool life measurements for optimal tool management. *International Journal of Machine Tools and Manufacture*, v.43, n.4, p.359-368.
- 59 DORNFELD, D. A. (1994). In process recognition of cutting states. Review. *JSME International Journal, Series C*, v.37, n.4, p.638-650.
- 60 IWATA, K.; MORIWAKI, T. (1978). Cutting state identification and in-process tool wear sensing by acoustic emission analysis. *Bulletin of the Japan Society of Precision Engineering*, v.12, n.4, p.213-214.
- 61 KANNATEY-ASIBU JR., E.; DORNFELD, D. A. (1982). A study of tool wear using statistical analysis of metal cutting acoustic emission. *Wear*, v.76, n.2, p.247-261.
- 62 LIANG, S. Y.; DORNFELD, D. A. (1989). Tool wear detection using time series analysis of acoustic emission. *ASME Journal of Engineering for Industry*, v.111, n.3, p.199-205.
- 63 MORIWAKI, T. (1980). Detection for cutting tool fracture by acoustic emission measurement. *Annals of the CIRP*, v.29, n.1, p.35-39.
- 64 EMEL, E.; KANNATEY-ASIBU JR., E. (1988). Tool failure monitoring in turning by pattern recognition analysis of AE signals. *ASME Journal of Engineering for Industry*, v.110, n.2, p.137-145.
- 65 NIU, Y. M. *et al.* (1998). Multi-category classification of tool conditions using wavelet packets and ART2 network. *ASME Journal of Manufacturing Science and Engineering*, v.120, n.4, p.807-816.
- 66 CHRYSOLOURIS, G.; DOMROESE, M.; BEAULIEU, P. (1992). Sensor synthesis for control of manufacturing processes. *ASME Journal of Engineering for Industry*, v.114, n.2, p.158-174.
- 67 LEEM, C. S.; DORNFELD, D. A.; DREYFUS, S. E. (1995). A customized neural network for sensor fusion in on-line monitoring of cutting tool wear. *ASME Journal of Engineering for Industry*, v.117, n.2, p.152-159.
- 68 HONG, G. S.; RAHMAN, M.; ZHOU, Q. (1996). Using neural network for tool condition monitoring based on wavelet decomposition. *International Journal of Machine Tools and Manufacture*, v.36, n.5, p.551-566.

- 69 RAHMAN, M.; ZHOU, Q.; HONG, G. S. (1995). On-line cutting state recognition in turning using a neural network. *The International Journal of Advanced Manufacturing Technology*, v.10, n.2, p.87-92.
- 70 DIMLA, D. E.; LISTER, P. M.; LEIGHTON, N. J. (1997). Neural network solutions to the tool condition monitoring problem in metal cutting – a critical review of methods. *International Journal of Machine Tools and Manufacturing*, v.37, n.9, p.1219-1241.
- 71 ORABY, S. E.; HAYHURST, D. R. (1991). Development of models for tool wear force relationships in metal cutting. *International Journal of Mechanical Science*, v.33, n.2, p.125-138.
- 72 CHOI, D.; KWON, W. T.; CHU, C. N. (1999). Real-time monitoring of tool fracture in turning using sensor fusion. *The International Journal of Advanced Manufacturing Technology*, v.15, n.5, p.305-310.
- 73 LEE, J. M.; CHOI, D. K.; CHU, C. N. (1994). Real-time tool breakage monitoring for NC turning and drilling. *Annals of the CIRP*, v.43, n.1, p.81-84.
- 74 LEE, J. M. *et al.* (1994). In-process tool breakage detection using a built-in force sensor and an AE sensor. *Transactions of the NAMRI of SME*, v.22, p.91-97.
- 75 DU, R.; ELBESTAWI, M. A.; LI, S. (1992). Tool condition monitoring in turning using fuzzy set theory. *International Journal of Machine Tools and Manufacture*, v.32, n.6, p.781-796.
- 76 LI, S.; ELBESTAWI, M. A. (1996). Tool condition monitoring in machining by fuzzy neural networks. *ASME Journal of Dynamic Systems, Measurement, and Control*, v.118, n.4, p.665-672.
- 77 LEE, L. C.; LEE, K. S.; GAN, C. S. (1989). On the correlation between dynamic cutting force and tool wear. *International Journal of Machine Tools and Manufacture*, v.29, n.3, p.295-303.
- 78 DORNFELD, D. A. (1992). Sensor fusion. In: ZUECH, N. *Handbook of intelligent sensors for industrial automation*. Reading: Addison-Wesley, Cap.16, p.419-508.
- 79 GHASEMPOOR, A.; MOORE, T. N.; JESWIEST, J. (1998). On-line wear estimation using neural networks. *Proceedings of the Institution of Mechanical Engineers (IMEchE), Journal of Engineering Manufacture*, v.212, n.B-2, p.105-112.

- 80 AMBARDAR, A. (1999). *Analog and digital signal processing*. 2.ed., Pacific Grove: Books/Cole Publishing Company of ITP, 807p.
- 81 SIGNAL CONDITIONING TUTORIAL (2001). *National Instrument NI Developer Zone*. Development Library, 5p. <http://www.ni.com>.
- 82 LIU, Q.; ALTINTAS, Y. (1999). On-line monitoring of flank wear in turning with multi-layered feed-forward neural network. *International Journal of Machine Tools and Manufacture*, v.39, n.12, p.1945-1959.
- 83 SILVA, R. G. *et al.* (1998). Tool wear monitoring of turning operations by neural network and expert system classification of a feature set generated from multiple sensors. *Mechanical Systems and Signal Processing*, v.12, n.2, p.319-332.
- 84 DU, R.; ELBESTAWI, M. A.; WU, S. M. (1995a). Automated monitoring of manufacturing processes, part 1: monitoring methods. *ASME Journal of Engineering for Industry*, v.117, n.2, p.121-132.
- 85 LEE, J. H.; LEE, S. J. (1999). One-step ahead prediction of flank wear using cutting force. *International Journal of Machine Tools and Manufacture*, v.39, n.11, p.1747-1760.
- 86 LIU, Q.; ALTINTAS, Y. (1999). On-line monitoring of flank wear in turning with multi-layered feed-forward neural network. *International Journal of Machine Tools and Manufacture*, v.39, n.12, p.1945-1959.
- 87 RANGWALA, S.; DORNFELD, D. (1990b). A study of acoustic emission generated during orthogonal metal cutting – 2: spectral analysis. *International Journal of Mechanical Science*, v.33, n.6, p.489-499.
- 88 SAINI, D. P.; PARK, Y. J. (1996). A quantitative model of acoustic emissions in orthogonal cutting operations. *Journal of Materials Processing Technology*, v.58, n.4, p.343-350.
- 89 MONTGOMERY, D.; RUNTER, G. (1998). *Applied statistics and probability for engineers*. 2.ed. New York: John Wiley & Sons, 625p.
- 90 JEMIELNIAK, K.; OTMAN, O. (1998). Catastrophic tool failure detection based on acoustic emission signal analysis. *Annals of the CIRP*, v.47, n.1, p.31-34.

- 91 JEMIELNIAK, K.; OTMAN, O. (1998). Tool failure detection based on analysis of acoustic emission signals. *Journal of Materials Processing Technology*, v.76, n.1-3, p.192-197.
- 92 KO, T. J.; CHO, D. W.; LEE, J. M. (1992). Fuzzy pattern recognition for tool wear monitoring in diamond turning. *Annals of the CIRP*, v.41, n.1, p.125-128.
- 93 LOMBARDO, A.; MASNATA, A.; SETTINERI, L. (1997). In-process tool-failure detection by means of AR models. *The International Journal of Advanced Manufacturing Technology*, v.13, n.2, p.86-94.
- 94 KO, T. J.; CHO, D. W. (1994). Tool wear monitoring in diamond turning by fuzzy pattern recognition. *ASME Journal of Engineering for Industry*, v.116, n.2, p.225-232.
- 95 LOSS, J. F.; BALBINOT, A.; ZARO, M. A. (2000). *Técnicas experimentais – aquisição de dados via computador*, cap.5 – análise de sinais. Laboratório de Medições Mecânicas, GMA-UFRGS. [http://www.ufrgs.br/lmm/353\\_6\\_5.htm](http://www.ufrgs.br/lmm/353_6_5.htm) (4 dez).
- 96 GRAPS, A. L. (1995). An introduction to wavelets. *IEEE Computational Science and Engineering*, v.2, n.2, p.50-61.
- 97 GONG, W.; OBIKAWA, T.; SHIRAKASHI, T. (1997). Monitoring of tool wear states in turning based on wavelet analysis. *JSME International Journal – Series C: Mechanical Systems, Machine Elements and Manufacturing*, v.40, n.3, p.447-451.
- 98 LI, X.; DONG, S.; YUAN, Z. (1999). Discrete wavelet transform for tool breakage monitoring. *International Journal of Machine Tools and Manufacture*, v.39, n.12, p.1935-1944.
- 99 TANSEL, I. N. *et al.* (1993) Monitoring drill conditions with wavelet based encoding and neural networks. *International Journal of Machine Tools and Manufacture*, v.33, n.4, p.559-575.
- 100 LI, X. (1998). Real-time detection of the breakage of small diameter drills with wavelet transform. *The International Journal of Advanced Manufacturing Technology*, v.14, n.8, p.539-543.
- 101 WU, Y.; DU, R. (1996). Feature extraction and assessment using wavelet packets for monitoring of machining processes. *Mechanical Systems and Signal Processing*, v.10, n.1, p.29-53.

- 102 BERGER, B. S. *et al.* (1998). Wavelet based cutting state identification. *Journal of Sound and Vibration*, v.213, n.5, p.813-827.
- 103 KAMARTHI, S. V.; KUMARA, S. R. T.; COHEN, P. H. (2000). Flank wear estimation in turning through wavelet representation of acoustic emission signals. *ASME Journal of Manufacturing Science and Engineering*, v.122, n.1, p.12-19.
- 104 LI, X.; ZHEJUN, Y. (1998). Tool wear monitoring with wavelet packet transform-fuzzy clustering method. *Wear*, v.219, n.2, p.145-154.
- 105 ALEXANDER, S. M.; GOR, T. B. (1998). Monitoring, diagnosis and control of industrial processes. *Computers and Industrial Engineering*, v.35, n.1-2, p.193-196.
- 106 KAMARTHY, S. V.; PITTNER, S. (1997). Fourier and wavelet transform for flank wear estimation: a comparison. *Mechanical Systems and Signal Processing*, v.11, n.6, p.791-809.
- 107 BUKKAPATNAM, S. T. S.; KUMARA, S. R. T.; LAKHTAKIA, A. (2000). Fractal estimation of flank wear in turning. *ASME Journal of Dynamic Systems, Measurement and Control*, v.122, n.1, p.89-94.
- 108 SILVA, R. G. *et al.* (2000) The adaptability of a tool wear monitoring system under changing cutting conditions. *Mechanical Systems and Signal Processing*, v.14, n.2, p.287-298.
- 109 MONOSTORI, L. *et al.* (1996). Machine learning approaches to manufacturing. Technical Report. *Annals of the CIRP*, v.45, n.2, p.675-712.
- 110 ZIMMERMANN, H.-J. (1998). A fresh perspective on uncertainty modeling: uncertainty vs. uncertainty modeling. In: AYYUB, B. M.; GUPTA, M. M. (1998). *Uncertainty analysis in engineering and science: fuzzy logic, statistics, and neural network approach*. Boston: Kluwer Academic Publishers, Cap.24, p.353-364.
- 111 KLUFT, W. (1992). Tool monitoring for mass production turning, drilling, milling and grinding. *Monitoring Technology for Improved Cutting Tool Performance and Predictive Maintenance Clinic – SME Conference*, Detroit – Michigan, USA, 24p., May.
- 112 ALSERMETTI, B. (1995). Automatic set-up of tool monitors by a CAM system. *Computers in Industry*, v.26, n.2, p.135-145.

- 113 MONOSTORI, L. (1997). Special issue of computers in industry on learning in intelligent manufacturing systems – editorial. *Computers in Industry*, v.33, n.1, p.1-3.
- 114 KECMAN, V. (2001). *Learning and soft computing: support vector machines, neural networks, and fuzzy logic models*. Cambridge: The MIT Press, 541p.
- 115 JIAA, C. L.; DORNFELD, D. A. (1998). A self-organizing approach to the prediction and detection of tool wear. *ISA Transactions*, v.37, n.4, p.239-255.
- 116 DU, R.; ELBESTAWI, M. A.; WU, S. M. (1995). Automated monitoring of manufacturing processes, part 2: applications. *ASME Journal of Engineering for Industry*, v.117, n.2, p.133-141.
- 117 BITTENCOURT, G. (1998). *Inteligência artificial: ferramentas e teorias*. Editora da UFSC, Florianópolis, 362p.
- 118 MONOSTORI, L.; EGRESITS, C. (1997). On hybrid learning and its application in intelligent manufacturing. *Computers in Industry*, v.33, n.1, p.111-117.
- 119 LOESCH, C.; SARI, S. T. (1996). *Redes neurais artificiais – ferramentas e teorias*. Blumenau: Editora da FURB, 166p.
- 120 ALMEIDA, S. L. R.; BERNARDO, V.; COPPINI, N. L. (1996). Aplicação de lógica fuzzy e redes neurais para a otimização de condições de usinagem. *Revista Máquinas e Metais*, v.31, n.365, p.98-106.
- 121 DIMLA, D. E.; LISTER, P. M. (2000). On-line metal cutting tool condition monitoring. II: tool state classification using multi-layer perceptron neural networks. *International Journal of Machine Tools and Manufacturing*, v.40, n.5, p.769-781.
- 122 DIMLA, D. E. (1999). Application of perceptron neural networks to tool-state classification in a metal-turning operation. *Engineering Applications of Artificial Intelligence*, v.39, n.12, p.471-477.
- 123 DAS, S.; CHATTOPADHYAY, A. B.; MURTHY, A. S. R. (1996). Force parameters for on-line tool wear estimation: a neural network approach. Contributed Article. *Neural Networks*, v.9, n.9, p.1639-1645.
- 124 DAS, S.; ROY, R.; CHATTOPADHYAY, A. B. (1996). Evaluation of wear of turning carbide inserts using neural networks. *International Journal of Machine Tools and Manufacturing*, v.36, n.7, p.789-797.

- 125 DUTTA, R. K.; PAUL, S.; CHATTOPADHYAY, A. B. (2000). Applicability of the modified back-propagation algorithm in tool condition monitoring for faster convergence. *ASME Journal of Materials Processing Technology*, v.98, n.3, p.299-309.
- 126 PURUSHOTHAMAN, S.; SRINIVASA, Y. G. (1994). A back-propagation algorithm applied to tool wear monitoring. *International Journal of Machine Tools and Manufacture*, v.34, n.5, p.625-631.
- 127 HARRIS, J. (2000). *An introduction to fuzzy logic applications*. Dordrecht: Kluwer Academic Publishers, 218p.
- 128 NASCIMENTO JR.; C. L.; YONEYAMA, T. (2000). *Inteligência artificial em controle e automação*. 1.ed. São Paulo: Edgard Blücher & FAPESP, 228p.
- 129 KOSKO, B. (1992). *Neural networks and fuzzy systems - a dynamical systems approach to machine intelligence*. New Jersey: Prentice-Hall, 449p.
- 130 KUO, R.; COHEN, P. H. (1998a). Intelligent tool wear estimation system through artificial neural networks and fuzzy modelling. *Artificial Intelligence in Engineering*, v.12, n.3, p.229-242.
- 131 KUO, R.; COHEN, P. H. (1998b). Manufacturing process control through integration of neural networks and fuzzy model. *Fuzzy Sets and Systems*, v.98, n.1, p.15-31.
- 132 KUO, R.; COHEN, P. H. (1999). Multi-sensor integration for on-line tool-wear estimation through radial basis function networks and fuzzy neural network. *Neural Networks*, v.12, n.2, p.355-370.
- 133 BALAZINSKI, M. *et al.* (2002). Tool condition monitoring using artificial intelligence methods. *Engineering Applications of Artificial Intelligence*, v.15, n.1, p.73-80.
- 134 VÖHRINGER, K. -D. (1990). Zerspanprozeß-überwachung in der Großserie sinnvoll einsetzen. *Werkstatt und Betrieb*, v.123, n.10, p.763-766.
- 135 FINCH, J. L.; KLINE, W. A. (1990). Application issues for tool monitoring systems on lathe. Present at *Tool and Machine Condition Monitoring Conference*, Society of Manufacturing Engineer, Aug 21-22, Chicago, Illinois.
- 136 LANGGUTT, T.;WEBER, A. (1991). Werkzeug-verschleiß- und -bruchüberwachung beim flexiblen Drehen, Bohren und Fräsen. *Werkstatt und Betrieb*, v.124, n.1, p.15-24.

- 137 YAO, Y.; FANG, X. D. (1991). Modeling of multivariate time series for tool wear estimation in finish turning. *International Journal of Machine Tools and Manufacture*, v.32, n.4, p.495-508.
- 138 GRABEC, I.; GRADISEK, E. GOVEKAR, E. (1999). A new method for chatter detection in turning. *Annals of the CIRP*, v.48, n.1, p.29-32.
- 139 NADJIR, A.; ÖZEL, T. (2000). Neural network modeling of flank wear for tool condition monitoring in orthogonal cutting of hardened steels. *IV International Conference on Engineering Design and Automation*, July 30 to Aug. 2, Orlando, Florida, USA, 6p.
- 140 KÖNIG, W.; LANGHAMMER, K.; SCHEMMEL, H. -U. (1972). Correlations between cutting force components and tool wear. *Annals of the CIRP*, v.21, n.1, p.19-20.
- 141 LAN, M. S.; DORNFELD, D. A. (1984). In-process tool fracture detection. *ASME Journal of Engineering for Industry*, v.111, n.2, p.111-118.
- 142 YOUN, J. -W.; YANG, M. -Y. (2001). A study on the relationships between static/ dynamic cutting force components and tool wear. *ASME Journal of Manufacturing Science and Engineering*, v.123, n.2, p.196-205.
- 143 COLWELL, L. V.; MAZUR, J. C. (1979). Real time computer diagnostics (a research tool metal cutting). *Annals of the CIRP*, v.28, n.1, p. 49-52.
- 144 NOVAK, A.; WIKLUND, H. (1996). On-line prediction of the tool life. *Annals of the CIRP*, v.45, n.1, p.93-96.
- 145 LEE, J. H.; KIM, D. E.; LEE, S. J. (1998). Statistical analysis of cutting force ratios for flank-wear monitoring. *Journal of Materials Processing Technology*, v.74, n.1-3, p.104-114.
- 146 SUKVITAYAWONG, S.; INASAKI, I. (1991). Optimization of turning process by cutting force measurement. *JSME International Journal, Series III – Vibration, Control Engineering, Engineering for Industry*, v.34, n.4, p.546-552.
- 147 OHBA, R. (1992). *Intelligent Sensor Technology*. Chichester: John Wiley & Sons, Wiley Series in Measurement Science and Technology, 167p.
- 148 HAYASHI, S. R.; THOMAS, C. E.; WILDES, D. G. (1988). Tool break detection by monitoring ultrasonic vibrations. *Annals of the CIRP*, v.37, n.1, p.61-64



- 149 DINIZ, A. E.; HARA, C. M. (1999). Using neural network to establish the end of turning tool life based on tool vibration signals. *Revista Ciência e Tecnologia*. Universidade Metodista de Piracicaba, v.7, n.14, p.67-74.
- 150 MILLER, R. K. *et al.* (1991). Process monitoring with acoustic emission. *ASNT Nondestructive Testing Handbook*. 2.ed. New Jersey: Physical Acoustic Corporation, v.5, n.14, p.467-511.
- 151 DORNFELD, D. A. (1999). Monitoração de processos por emissão acústica. *Revista Máquinas e Metais*, v.35, n.400, p.64-81.
- 152 KLAIBER, J. R.; DORNFELD, D. A.; LIU, J. J. (1990). Acoustic emission feedback for diamond turning. *Transactions of the NAMRI of SME*, v.18, p.113-119.
- 153 RANGWALA, S.; DORNFELD, D. (1991). A study of acoustic emission generated during orthogonal metal cutting – 1: energy analysis. *International Journal of Mechanical Science*, v.33, n.6, p.471-487.
- 154 RAVINDRA, H. V.; SRINIVASA, Y. G.; KRISHNAMURTHY, R. (1997). Acoustic emission for tool condition monitoring in metal cutting. *Wear*, v.212, n.1, p.78-84.
- 155 BLUM, T.; INASAKI, I. (1990). A study on acoustic emission from the orthogonal cutting process. *ASME Journal of Engineering for Industry*, v.112, n.3, p.203-211.
- 156 LI, X. (2002). A brief review: acoustic emission method for tool wear monitoring during turning. *International Journal of Machine Tools and Manufacture*, v.42, n.1, p.157-165.
- 157 MORIWAKI, T. (1983) Application of acoustic emission measurement to sensing of wear and breakage of cutting tool. *Bulletin of the Japan Society of Precision Engineering*, v.17, n.3, p.154-160.
- 158 SOUQUET, P. *et al.* (1987). Tool monitoring with acoustic emission industrial results and future prospects. *Annals of the CIRP*, v.36, n.1, p.57-60. /em francês/
- 159 INASAKI, I.; AIDA, S.; FUKUOKA, S. (1987). Monitoring system for cutting tool failure using an acoustic emission sensor. *JSME International Journal*, v.30, n.261, p.523-528.
- 160 WASCHKIES, E.; SKLARCZYK, C.; HEPP, K. (1994). Tool wear monitoring at turning. Technical Briefs. *ASME Journal of Engineering for Industry*, v.116, n.4, p.521-524.

- 161 KANNATEY-ASIBU JR., E.; DORNFELD, D. A. (1981). Quantitative relationships for acoustic emission from orthogonal metal cutting. *ASME Journal of Engineering for Industry*, v.103, n.3, p.330-340.
- 162 CHO, S. -S.; KOMVOPOULOS, K. (1997) Correlation between acoustic emission and wear of multi-layer ceramic-coated carbide tools. *ASME Journal of Manufacturing Science and Engineering*, v.119, n.2, p.238-246.
- 163 LEE, M. *et al.* (1988) Effects of tool geometry on acoustic emission intensity. *Annals of the CIRP*, v.37, n.1, p.57-60.
- 164 TETI, R. (1989). Tool wear monitoring through acoustic emission. *Annals of the CIRP*, v.38, n.1, p.99-102.
- 165 LIU, J. J.; DORNFELD, D. A. (1996). Modeling and analysis of acoustic emission in diamond turning. *ASME Journal of Manufacturing Science and Engineering*, v.118, n.2, p.199-207.
- 166 TETI, R.; DORNFELD, D. (1989). Modeling and experimental analysis of acoustic emission from metal cutting. *ASME Journal of Engineering for Industry*, v.111, n.3, p.229-237.
- 167 BEGGAN, C. *et al.* (1999). Using acoustic emission to predict surface quality. *The International Journal of Advanced Manufacturing Technology*, v.15, n.10, p.737-742.
- 168 LI, X.; VENUVINOD, P. K.; CHEN, M. K. (2000). Feed cutting force estimation from current measurement with hybrid learning. *The International Journal of Advanced Manufacturing Technology*, v.16, n.X, p.859-862.
- 169 TAKATA, S. *et al.* (1987). Tool breakage monitoring by means of fluctuations in spindle rotational speed. *Annals of the CIRP*, v.36, n.1, p.49-52.
- 170 PIRES, J. R.; DINIZ, A. E. (1996). Evitando o desperdício de ferramentas de torneamento – uma aplicação em chão-de-fábrica. *Revista Máquinas e Metais*, v.31, n.370, p.73-85.
- 171 STEIN, J. L.; HUH, K. (2002). Monitoring cutting forces in turning: a model-based approach. *ASME Journal of Manufacturing Science and Engineering*, v.124, n.1, p.26-31.

- 172 COLWELL, L. V. (1975). Cutting temperature versus tool wear. *Annals of the CIRP*, v.24, n.1, p.73-76.
- 173 CARVALHO, S. R. *et al.* (2003). Determinação da temperatura na interface cavaco-peça-ferramenta durante o processo de torneamento usando a técnica simulated annealing. *II Congresso Brasileiro de Engenharia de Fabricação*. Uberlândia, 18-21 de março/CD-ROM.
- 174 BORELLI, J. E. *et al.* (2000) Diagnóstico de estados de ferramenta nos processos de usinagem de alto desempenho com o uso de lógica fuzzy e imagens de infravermelho. /Apresentado ao *USINAGEM 2000 – Feira e Congresso*, São Paulo, 32p./
- 175 D'ERRICO, G. E. (1998). An adaptive system for turning process control based on tool temperature feedback. *Journal of Materials Processing Technology*, v. 78, n.1-3, p.43-47.
- 176 AY, H.; YANG, W. (1997). Heat transfer and life of metal cutting tool in turning. *International Journal of Heat and Mass Transfer*. v.41, n.3, p.613-623.
- 177 HAYKIN, S. (1999). *Neural networks: a comprehensive foundation*. 2.ed. Upper Saddle River: Prentice-Hall, 842p.
- 178 HECHT-NIELSEN, R. (1990). *Neurocomputing*. Reading: Addison-Wesley, 433p.
- 179 DOS SANTOS, A. L. B. (2001). Metodologia via redes neurais para a estimativa da rugosidade e do desgaste de ferramentas de corte no processo de fresamento frontal. Uberlândia, 187p. Tese (Doutorado) – Engenharia Mecânica, UFU.
- 180 KOVÁCS, Z. L. (1996). *Redes neurais artificiais – fundamentos e aplicações*. 2.ed. São Paulo: Collegium Cognito, 174p.
- 181 DEMUTH, H.; BEALE, M. (1998). *Neural network toolbox user's guide: computation, visualization, programming*. Version 3.0. The MathWorks, Inc., 742p.
- 182 DIMLA, D. E.; LISTER, P. M.; LEIGHTON, N. J. (1998). Automatic state identification in a metal turning operation using MLP neural networks and multivariate process parameters. *International Journal of Machine Tools and Manufacture*, v.38, n.4, p.343-352.

- 183 LEEM, C. S.; DORNFELD, D. A. (1996). Design and implementation of sensor-based tool-wear monitoring systems. *Mechanical Systems and Signal Processing*, v.10, n.4, p.439-458.
- 184 LEEM, C. S. (1997). A practical monitoring strategy for machining process control. *International Journal of Production Research*, v.35, n.4, p.1051-1066.
- 185 CHESTER, M. (1993). *Neural networks: a tutorial*. Englewood Cliffs: PTR Prentice Hall, 183p.
- 186 LI, X.; YUAN, Z. (1998). Tool wear monitoring with wavelet packet transform-fuzzy clustering method. *Wear*, v.219, n.2, p.145-154.
- 187 JAMMU, V. B.; DANAI, K.; MALKIN, S. (1993). Unsupervised neural network for tool breakage detection in turning. *Annals of the CIRP*, v.42, n.1, p.67-70.
- 188 OBIKAWA, T. *et al.* (1996) Tool wear monitoring for optimizing cutting conditions. *Journal of Materials Processing Technology*, v.62, n.4, p.374-379.
- 189 VOCABULÁRIO INTERNACIONAL DE METROLOGIA (1995). *Instituto Nacional de Metrologia, Normalização e Qualidade Industrial (INMETRO), Ministério da Indústria, do Comércio e do Turismo (MICT)*, 25p.
- 190 GERDAU (1998). *Manual de aços*. Aços Finos Piratini, Edição atualizada, 98p.
- 191 AB SANDVIK COROMANT (2000). *Catálogo Ferramentas para Torneamento*.
- 192 ISCAR (1999). *Catálogo Iscar Turn Plus*.
- 193 WANG, L.; MEHRABI, M. G.; K-ASIBU JR., E. (2002). Hidden markov model-based tool wear monitoring in turning. *ASME Journal of Manufacturing Science and Engineering*, v.124, n.3, p.651-8.
- 194 JEMIELNIAK, K. (2000). Some aspects of AE applications in tool condition monitoring. *Ultrasonics*, v.38, n.1-8, p.604-608.
- 195 JEMIELNIAK, K. (2001). Some aspects of acoustic emission signal pre-processing. *Journal of Materials Processing Technology*, v.109, n.X, p.242-247.
- 196 CHIAVENATO, I. (1991). *Iniciação à administração da produção*. São Paulo: Makron Books, 145p.

- 197 ISERMANN, R.; BALLÉ, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice*, v.5, n.5, p.709-719.
- 198 RESTIVO, F. J. O. (1998). *Processamento digital de sinal*. Faculdade de Engenharia da Universidade do Porto, Departamento de Engenharia Eletrotécnica e de Computadores, 105p./apostila/
- 199 CALLISTER JR., W. D. (2002). *Ciência e engenharia de materiais: uma introdução*. 5.ed. Rio de Janeiro: LTC Editora, 589p.
- 200 CATÁLOGO DE MATERIAIS DE REFERÊNCIA (2003). Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT), Catálogo 001, 16p.

## Bibliografia Complementar

- 201 ABE, S. (2001). *Pattern classification: neuro-fuzzy methods and their comparison*. London: Springer-Verlag., 327p.
- 202 ABU-ZAHRA, N. H.; YU, G. (2003). Gradual wear monitoring of turning inserts using wavelet analysis of ultrasound waves. *International Journal of Machine Tools and Manufacture*, v.43, n.4, p.337-343.
- 203 AMBARDAR, A. (1999). *Analog and digital signal processing*. 2.ed., Pacific Grove: Books/Cole Publishing Company of ITP, 807p.
- 204 ANSELMETTI, B. (1995). Automatic set-up of tool monitors by a CAM system. *Computers in Industry*, v.26, n.2, p.135-145.
- 205 BECKWITH, T. G.; MARANGONI, R. D.; LIENHARD V, J. H. (1993). *Mechanical measurements*, 5.ed., Reading: Addison-Wesley, 876p.
- 206 BUKKAPATNAM, S. T. S.; KUMARA, S. R. T.; LAKHTAKIA, A. (1999). Analysis of acoustic emission signals in machining. *ASME Journal of Manufacturing Science and Engineering*, v.121, n.4, p.568-576


- 207 CHOUDHURY, S. K.; GOUDIMENKO, N. N.; KUDINOV, V. A. (1997). On-line control of machine tool vibration in turning. *International Journal of Machine Tools and Manufacture*, v.37, n.6, p.801-811.
- 208 COELHO, L. S. (1997). *Metodologias da inteligência computacional em identificação e controle de processos: abordagem nebulosa, evolutiva e neural*. Florianópolis. 144p. Dissertação (Mestrado), Ciência da Computação – UFSC.
- 209 CZOGALA, E.; LESKI, J. (2000). *Fuzzy and neuro-fuzzy intelligent systems*. Heidelberg: Pysica-Verlag, 193p.
- 210 DANAI, K.; ULSOY, A. G. (1987). A dynamic state model for on-line tool wear estimation in turning. Technical Briefs. *ASME Journal of Engineering for Industry*, v.109, n.4, p.396-399.
- 211 DINI G. (1997). Literature database on applications of artificial intelligence methods in manufacturing engineering. Technical Report. *Annals of the CIRP*, v.46, n.2, p.681-690.
- 212 DOLINŠEK, S. *et al.* (1999). An intelligent AE sensor for the monitoring of finish machining process. *The 2nd International Conference on IPMM – Intelligent Processing and Manufacturing of Materials*, July 10 - 15, Honolulu, Hawaii, 7p.
- 213 DOMÍNGUES, A. R.; GONZÁLEZ, L. J. (2002). Fault diagnosis of multi-tooth machine tool based on statistical signal processing. 15<sup>th</sup> IFAC – World Congress on Automatic Control, July 21-26, Barcelona, Spain, 6p.
- 214 GOMES, J.; VELHO, L.; GOLDENSTEIN, S. (1997). *Wavelets: teoria, software e aplicações*. XXI Colóquio Brasileiro de Matemática, IMPA, Rio de Janeiro, RJ, 21-25 jun., 216p.
- 215 GOVEKAR, E.; GRABEC, I. (1994). Self-organizing neural network application to drill wear classification. *ASME Journal of Engineering for Industry*, v.116, n.2, p.233-238.
- 216 GRABEC, I.; KULJANIC, E. (1994). Characterization of manufacturing processes based upon acoustic emission analysis by neural networks. *Annals of the CIRP*, v.43, n.1, p.77-80.
- 217 HOFFMANN, P.; MARGOT, R.; SCHEER, C. (2000). Machine integrated monitoring system: using adapted measuring systems for reliable process monitoring. *IWF-ETH*, Zürich, 4p. <http://www.iwf.bepi.ethz.ch/projekte/mms/eng/> (30 Nov.).

- 218 Hu, W. *et al.* (2001). An intelligent integrated system scheme for machine tool diagnostics. *The International Journal of Advanced Manufacturing Technology*, v.18, n.11, p.836-841.
- 219 KLINE, W. A. (1992). Machine tool monitoring systems. In: ZUECH, N. *Handbook of intelligent sensors for industrial automation*. Reading: Addison-Wesley, Cap.1, p.1-20.
- 220 KLIR, G. J.; FOLGER, T. A. (1988). *Fuzzy sets, uncertainty, and information*. Prentice-Hall, Inc., New Jersey, 355p.
- 221 KOREN, Y. *et al.* (1991). Flank wear estimation under varying cutting conditions. *ASME Journal of Dynamic Systems, Measurement, and Control*, v.113, p.300-307.
- 222 LIANG, S. Y.; HECKER, R. L.; LANDERS, R. G. (2002). Machining process monitoring and control: the state-of-the-art. *Proceedings of the Institution of Mechanical Engineers (IMEchE)*, ASME International Mechanical Engineering Congress & Exposition, Nov. 17-22, New Orleans, Louisiana, p.1-12. To confirm.
- 223 LIU, T. I.; ANANTHARAMAN, K. S. (1994). Intelligent classification and measurement of drill wear. *ASME Journal of Engineering for Industry*, v.116, n.3, p.392-397.
- 224 LU, S. C-Y. (1990). Machine learning approaches to knowledge synthesis and integration tasks for advanced engineering automation. *Intelligent Manufacturing Systems – IMS`89. Computers in Industry*, v.15, p.105-120.
- 225 MATHEWS, P. G.; SHUNMUGAM, M. S. (1999). Condition monitoring in reaming through acoustic emission signals. *Journal of Materials Processing Technology*, v.86, n.1-3, p.81-86.
- 226 MEREDITH, D. (1998). Practical tool condition monitoring. *SME Manufacturing Engineering*, v.120, n.1, p.34-39.
- 227 NAUCK, D. D. (2000). *Data analysis with neuro-fuzzy methods*. Habilitationsschrift zur Erlangung des akademischen Grades "doctor rerum naturalium habilitatus" (Dr.rer.nat.habil.), genehmigt durch die Fakultät für Informatik der Otto-von-Guericke-Universität Magdeburg.
- 228 ÖZEL, T.; NADGIR, A. (2002). Prediction of flank wear by using back propagation neural network modelling when cutting hardened H-13 steel with chamfered and honed

- CBN tools. *International Journal of Machine Tools and Manufacture*, v.42, n.2, p.287-297.
- 229 PARK, J. -J.; ULSOY, A. G. (1992). On-line tool wear estimation using force measurement and a nonlinear observer. *ASME Journal of Dynamic Systems, Measurement, and Control*, v.114, n.4, p.666-672.
- 230 PEKLENIK, J.; JERELE, A. (1992). Some basic relationships for identification of the machining processes. *Annals of the CIRP*, v.41, n.1, p.155-159.
- 231 POLIKAR, R. (2002). *The wavelet tutorial*. Rowan University, College of Engineering Web Servers. <http://engineering.rowan.edu/%7epolihar/WAVELETS/WTtutorial.html> (21 Feb).
- 232 RAJ, K. H. *et al.* (2000). Modeling of manufacturing process with Ann's for intelligent manufacturing. *International Journal of Machine Tools and Manufacture*, v.40, n.6, p.851-868.
- 233 SANTOCHI, M. *et al.* (1997). A sensor-integrated tool for cutting force monitoring. *Annals of the CIRP*, v.46, n.1, p.49-52.
- 234 SILVA, R. G. A. A. (2001). Development of a real-time tool condition monitoring system for turning. *5<sup>th</sup> Interamerican Congress on Computers Applied to the Process Industry (CAIP)*, Oct. 22-25, Campos do Jordão, SP, Brazil, 4p.
- 235 SOKOLOWSKI, A.; KOSMOL, J. (2001). Selected examples of cutting process monitoring and diagnostics. *Journal of Materials Processing Technology*, v.113, n.1-3, p.322-330.
- 236 SZECSEI, T. (1998). Automatic cutting-tool condition monitoring on CNC lathes. *Journal of Materials Processing Technology*, v.77, n.1-3, p.64-69.
- 237 TETI, R. (1995). A review of tool condition monitoring literature data base. 45<sup>th</sup> General Assembly. *Annals of the CIRP*, v.44, n.2, p.659-666.
- 238 TETI, R.; LA COMMARE, U. (1992). Cutting conditions and work material state identification through acoustic emission methods. *Annals of the CIRP*, v.41, n.1, p.89-92.
- 239 TSOUKALAS, L. H.; UHRIG, R. E. (1997). *Fuzzy and neural approaches in engineering*. New York: John Wiley & Sons, 519p.




- 240 ULSOY, A. G.; KOREN, Y. (1993). Control of machining processes. *ASME Journal of Dynamic Systems, Measurement, and Control*, v.115, p.301-308.
- 241 VACHTSEVANOS, G. J., KIM, S. ECHAUZ, J. R. (1998). Neuro-fuzzy approaches to decision making: a comparative study with an application to check authorization. *Journal of Intelligent and Fuzzy Systems*, v.6, n.2, p.259-278.
- 242 WILCOX, S. J.; REUBEN, R. L.; SOUQUET, P. (1997). The use of cutting force and acoustic emission signals for the monitoring of tool insert geometry during rough face milling. *International Journal of Machine Tools and Manufacture*, v.37, n.4, p.481-494.
- 243 YAN, D.; EL-WARDANY, T. I.; ELBESTAWI, M. A. (1995). A multi-sensor strategy for tool failure detection in milling. *International Journal of Machine Tools and Manufacture*, v.35, n.3, p.383-398.
- 244 YAO, Y.; FANG, X. D.; ARNDT, G. (1990). Comprehensive tool wear estimation in finish-machining via multivariate time-series analysis of 3-D cutting forces. *Annals of the CIRP*, v.39, n.1, p.57-60.
- 245 YAO, Y.; FANG, X. D.; ARNDT, G. (1991). On-line estimation of groove wear in the minor cutting edge for finish machining. *Annals of the CIRP*, v.40, n.1, p.41-44.
- 246 ZHOU, J. M.; ANDERSSON, M.; STÄHL, J. -E. (1997). Cutting tool fracture prediction and strength evaluation by stress identification, part I: stress model. *International Journal of Machine Tools and Manufacture*, v.37, n.12, p.1691-1714.



"Embora ninguém possa voltar atrás e fazer um novo começo,  
qualquer um pode começar agora e fazer um novo fim".

FRANCISCO CÂNDIDO XAVIER



## A1 Calibração da Plataforma Piezelétrica 9257A


Os valores de sensibilidade (T) dos canais X, Y e Z fornecidos pelo fabricante para a plataforma piezelétrica KISTLER modelo 9257A são respectivamente  $-7,82$  pC/N,  $-7,85$  pC/N e  $-3,72$  pC/N. Com o intuito de comprovar a precisão e a exatidão dos valores, foram determinadas as características de resposta do sistema de medição a partir de carregamentos com valores padronizados de força.

O funcionamento do sistema de calibração baseia-se no princípio de alavanca, onde a força resultante ( $F_R$ ) é proporcional à massa-padrão aplicada ( $m_p$ ), através da relação entre os comprimentos (L e K) e da aceleração da gravidade ( $g = 9,80665$  m/s<sup>2</sup>):

$$F_R = \frac{L}{K} \times g \times m_p \quad (\text{A.1})$$

Assim,  $F_R = 58,84 \times m_p$ . As massas-padrão ( $m_p$ ) usadas na calibração foram: até 20 kg para  $F_f$  (X); até 10 kg para  $F_p$  (Y); até 30 kg para  $F_c$  (Z).


A figura A.1 mostra as fotos do procedimento de calibração.



Canal X




Canal Y



Canal Z


**Figura A.1** – Procedimento de calibração da plataforma piezelétrica 9257A

As figuras A.2, A.3 e A.4 mostram respectivamente as análises de regressão dos valores de capacitância (pC) e força (N) para os canais X, Y e Z da plataforma, mostrando que os valores de sensibilidade "T" diferem percentualmente dos fornecidos pelo fabricante de 4,3%, 4,7% e 1,6% respectivamente.




**Figura A.2** – Análise de regressão para o canal X da plataforma 9257A

Baseando-se nos resultados tem-se, por exemplo, que a capacitância de **-7,48 pC** gerada no canal X da plataforma (fig. A.2) corresponde na realidade a uma tensão elétrica de 1,0 V e a uma força de 200 N (fator de escala  $S = 200$ ) aplicada na direção de avanço.



**Figura A.3** – Análise de regressão para o canal Y da plataforma 9257A

A sensibilidade da figura A.3 mostra que a capacitância de **-7,51 pC** gerada no canal Y da plataforma corresponde a uma tensão elétrica de 1,0 V.



**Figura A.4** – Análise de regressão para o canal Z da plataforma 9257A

A sensibilidade da figura A.4 mostra que a capacitância de **-3,66 pC** gerada no canal Z da plataforma corresponde a uma tensão elétrica de 1,0 V.

## A2 Valores de Força, Vibração, Rugosidade e Tempo de Vida da Ferramenta para Diferentes Parâmetros de Usinagem

A tabela A.1 mostra as 24 diferentes combinações dos parâmetros de corte escolhidos para a análise dos valores de força, vibração e rugosidade, além dos tempos de vida da ferramenta, estimados a partir da equação 3.1:

$$\left(\frac{T}{60}\right)^n = \frac{C_v \cdot \left(0,2 \cdot \frac{a_p}{f}\right)^g}{v_c \cdot (a_p \cdot f)^s} \quad (3.1)$$

A peça de aço ABNT 1040 com dureza de aproximadamente 156 HB (figura 8.3) foi usinada com inserto de metal-duro de alta qualidade. Portanto, os valores encontrados para as variáveis foram, segundo STEMMER [21]:  $C_v = 215 \text{ m/min}$ ;  $n = 0,2$ ;  $g = 0,14$  e  $s = 0,28$ .

Como se deseja o menor tempo de vida possível de modo que se possam avaliar as falhas precoces da ferramenta de corte (desgastes e avarias), o tempo teórico estimado escolhido para a vida da ferramenta foi  $T = 16,1 \text{ min}$ . Assim, as condições de corte adotadas foram  $v_c = 350 \text{ m/min}$ ,  $a_p = 1,5 \text{ mm}$  e  $f = 0,3 \text{ mm}$ .

**Tabela A.1** – Combinações dos parâmetros de corte escolhidos para a análise




Condição	$v_c$ [m/min]	$a_p$ [mm]	$f$ [mm]	$F_r$ [N]	$NF_r$ [%]	$F_p$ [N]	$NF_p$ [%]	$F_c$ [N]	$NF_c$ [%]	Vib [V]	$R_a$ [ $\mu$ m]	$R_{a-teor.}$ [ $\mu$ m]	Tempo [min]
1	180	1,0	0,15	208	39	268	50	417	78	0,392	1,27	0,90	2540
2	240	1,0	0,15	199	38	270	51	405	77	0,295	1,15	0,90	603
3	290	1,0	0,15	189	39	250	52	366	76	0,226	0,79	0,90	234
4	350	1,0	0,15	184	38	254	52	371	76	0,242	0,66	0,90	91,4
5	180	1,0	0,22	234	35	313	47	537	81	0,584	1,88	1,94	1137
6	240	1,0	0,22	227	35	305	47	526	81	0,528	1,86	1,94	270
7	290	1,0	0,22	235	35	320	48	531	80	0,530	2,31	1,94	105
8	350	1,0	0,22	243	36	323	48	532	80	0,496	1,84	1,94	40,9
9	180	1,0	0,30	262	33	368	46	668	83	0,728	3,48	3,61	593
10	240	1,0	0,30	257	32	363	45	673	83	0,831	3,75	3,61	141
11	290	1,0	0,30	249	31	375	46	670	83	0,688	3,66	3,61	54,6
12	350	1,0	0,30	240	31	358	46	639	83	0,890	4,16	3,61	21,3
13	180	1,5	0,15	297	38	384	49	623	79	0,533	1,27	0,90	1913
14	240	1,5	0,15	292	39	380	50	587	77	0,442	1,02	0,90	454
15	290	1,5	0,15	285	38	361	48	590	79	0,323	0,85	0,90	176
16	350	1,5	0,15	300	41	369	51	550	76	0,306	1,26	0,90	68,8
17	180	1,5	0,22	354	36	456	46	802	81	0,834	2,25	1,94	856
18	240	1,5	0,22	351	37	431	46	755	81	0,640	2,19	1,94	203
19	290	1,5	0,22	329	36	410	45	746	82	0,559	2,26	1,94	78,8
20	350	1,5	0,22	368	39	453	48	754	79	0,620	2,16	1,94	30,8
21	180	1,5	0,30	394	34	494	42	980	84	1,073	3,82	3,61	446
22	240	1,5	0,30	386	35	483	43	924	83	0,992	3,86	3,61	106
23	290	1,5	0,30	361	33	446	40	941	85	0,654	3,59	3,61	41,1
24	350	1,5	0,30	351	32	431	40	938	86	0,804	3,87	3,61	16,1

### A3 Variações Percentuais dos Sinais de Força


Efetuuou-se a aquisição de sinais de força no torneamento a seco do aço ABNT 1040 com ferramenta de metal-duro utilizando  $v_c = 350$  m/min;  $f = 0,3$  mm;  $a_p = 1,5$  mm.

As variações percentuais dos sinais de força com o aumento da largura da marca de desgaste de flanco (VB) dos gumes 1, 2 e 3 apresentam um comportamento determinístico, enquanto que os comportamentos dos resultados relativos ao gume 4 apresentam comportamento aleatório (houve lascamento).


As figuras A.5, A.6 e A.7 mostram respectivamente os gráficos das variações percentuais das componentes da força de usinagem – “ $F_r$ ”, “ $F_p$ ” e “ $F_c$ ” – com o aumento de “VB”.




As figuras A.8, A.9 e A.10 mostram respectivamente os gráficos das variações percentuais das componentes normalizadas da força de usinagem – “ $NF_f$ ”, “ $NF_p$ ” e “ $NF_c$ ” – com o aumento de “VB”.



**Figura A.8** – Variação percentual de “ $NF_f$ ” com o aumento de “VB”




**Figura A.9** – Variação percentual de “ $NF_p$ ” com o aumento de “VB”




**Figura A.10** – Variação percentual de “ $NF_c$ ” com o aumento de “VB”


As figuras A.11, A.12 e A.13 mostram respectivamente os gráficos das variações percentuais das relações entre as componentes da força de usinagem – “ $R_1$ ”, “ $R_2$ ” e “ $R_3$ ” – com o aumento de “VB”.



**Figura A.11** – Variação percentual de “ $R_1$ ” com o aumento de “VB”



**Figura A.12** – Variação percentual de “ $R_2$ ” com o aumento de “VB”



**Figura A.13** – Variação percentual de “ $R_3$ ” com o aumento de “VB”



## A4 Resultados Finais (Tabelados)

As tabelas A.2, A.3 e A.4 mostram os resultados obtidos via MATLAB<sup>®</sup> dos experimentos finais de comprovação do **Diagnóstico de Falhas e Prognóstico do Fim de Vida** para os gumes A, B e C, respectivamente (Capítulo 10).

Para as tabelas:

**T** [min] = tempo de vida decorrido da ferramenta (somando-se os tempos de cada passe, calculados com base na equação 10.1)

**VB** [mm] = largura da marca de desgaste de flanco medido diretamente via sistema de aquisição de imagens (item 8.1.4);

**VB<sub>est</sub>** [mm] = largura da marca de desgaste de flanco estimado via RNA direta 5-20-1 com algoritmo de treinamento por retropropagação flexível (arquitetura de rede definida e testada no item 8.5);

**T<sub>v</sub>** [min] = tempo de vida restante da ferramenta (calculado a partir do tempo de vida decorrido "T");

**T<sub>est</sub>** [min] = tempo de vida estimado da ferramenta a partir da equação (9.1), onde **Td** é a tendência dos resultados e **Re** é a repetitividade.

**Tabela A.2** – Resultados obtidos para o gume A

Passe	T [min]	VB [mm]	VB <sub>est</sub> [mm]	T <sub>v</sub> [min]	T <sub>res</sub>	
					Td [min]	Re [min]
0	0,0	0,000	0,000	17,6	20,0	± 0,0
1	0,9	0,045	0,046	16,7	18,7	± 1,6
2	1,7	0,060	0,054	15,9	18,1	± 2,0
3	2,5	0,071	0,056	15,1	17,9	± 2,1
5	4,1	0,087	0,061	13,5	17,5	± 2,4
7	5,5	0,099	0,078	12,1	15,7	± 3,4
9	6,7	0,108	0,080	10,9	15,5	± 3,5
11	7,9	0,115	0,088	9,7	14,7	± 3,9
14	9,4	0,121	0,093	8,2	14,1	± 4,1
16	10,3	0,137	0,123	7,3	10,6	± 5,2
19	12,8	0,150	0,133	4,8	9,5	± 5,4
21	14,3	0,168	0,141	3,3	8,5	± 5,5
23	15,7	0,181	0,168	1,9	5,9	± 5,3
24	16,4	0,191	0,193	1,2	3,8	± 4,5
25	17,0	0,200	0,195	0,6	3,7	± 4,4
26	17,6	0,320	0,222	0,0	2,1	± 3,0

**Tabela A.3** – Resultados obtidos para o gume B

Passe	T [min]	VB [mm]	VB <sub>est</sub> [mm]	T <sub>v</sub> [min]	T <sub>res</sub>	
					Td [min]	Re [min]
0	0,0	0,000	0,000	18,7	20,0	± 0,0
1	0,9	0,076	0,087	17,8	14,8	± 3,8
2	1,7	0,095	0,109	17,0	12,2	± 4,8
3	2,5	0,105	0,114	16,2	11,7	± 5,0
5	4,1	0,126	0,117	14,6	11,2	± 5,1
7	5,5	0,139	0,118	13,2	11,1	± 5,1
9	6,7	0,144	0,124	12,0	10,5	± 5,2
11	7,9	0,146	0,125	10,8	10,4	± 5,2
14	9,4	0,150	0,125	9,3	10,3	± 5,3
16	10,3	0,154	0,157	8,4	6,9	± 5,4
19	12,8	0,156	0,165	5,9	6,1	± 5,3
21	14,3	0,162	0,166	4,4	6,1	± 5,3
23	15,7	0,168	0,180	3,0	4,8	± 4,9
24	16,4	0,171	0,188	2,3	4,2	± 4,6
25	17,0	0,175	0,200	1,7	3,3	± 4,1
26	17,6	0,178	0,211	1,1	2,7	± 3,6
27	18,2	0,182	0,217	0,5	2,4	± 3,2
28	18,7	0,246	0,260	0,0	0,0	± 0,0

**Tabela A.4** – Resultados obtidos para o gume C

Passe	Tempo [min]	VB [mm]	VB <sub>est</sub> [mm]	T <sub>v</sub> [min]	T <sub>res</sub>	
					Td [min]	Re [min]
0	0,0	0,000	0,000	17,6	20,0	± 0,0
1	0,9	0,053	0,090	16,7	14,4	± 4,0
2	1,7	0,064	0,097	15,9	13,7	± 4,3
3	2,5	0,075	0,100	15,1	13,2	± 4,4
5	4,1	0,108	0,104	13,5	12,8	± 4,6
7	5,5	0,122	0,115	12,1	11,5	± 5,0
9	6,7	0,155	0,133	10,9	9,4	± 5,4
11	7,9	0,163	0,143	9,7	8,3	± 5,5
14	9,4	0,170	0,170	8,2	5,7	± 5,2
16	10,3	0,182	0,193	7,3	3,8	± 4,4
19	12,8	0,201	0,199	4,8	3,4	± 4,2
21	14,3	0,207	0,204	3,3	3,1	± 3,9
23	15,7	0,222	0,213	1,9	2,6	± 3,5
24	16,4	0,228	0,216	1,2	2,4	± 3,3
25	17,0	0,233	0,220	0,6	2,2	± 3,1
26	17,6	0,236	0,237	0,0	1,5	± 2,1